

**UNIVERSIDAD AUTÓNOMA DE MADRID**

**FACULTAD DE PSICOLOGÍA**

Doctorado en Metodología de las Ciencias del Comportamiento y la Salud



**Uso de la prueba Chi-cuadrado del modelo de  
independencia como fuente de evidencia empírica en  
Análisis Factorial Confirmatorio**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR PRESENTADA POR

Daniel Ondé Pérez

Director

Jesús M<sup>a</sup> Alvarado Izquierdo

Madrid, 2017

© Daniel Ondé Pérez



Dedicado a mis padres a  
quienes les debo todo, y a la  
memoria (o a su ausencia)...

Se puede  
llegar de otra manera.

## AGRADECIMIENTOS

El trabajo que se presenta en estas páginas no habría sido posible sin la orientación y el apoyo de mi director de tesis Jesús M<sup>a</sup> Alvarado. Desde que nos conocemos, los debates y reflexiones compartidos han sido muy significativos y enriquecedores para mí, así como su inestimable acompañamiento durante todo el proceso. Sus respuestas y valoraciones sobre los distintos avances que le he ido presentando durante todo este proceso de aprendizaje nunca se hicieron esperar. Siempre me habló claro. Siempre ha estado ahí. Espero que esta magnífica relación pueda mantenerse durante muchos años más.

También quiero agradecer la magnífica revisión realizada por mi tutora académica Carmen Ximénez de la versión preliminar de este trabajo de tesis. Sin duda, sus aportaciones y sugerencias, así como su conocimiento sobre los temas abordados, han contribuido de forma importante a enriquecer y mejorar este trabajo.

No me puedo olvidar de mencionar en estos agradecimientos a mi mujer Elena por su permanente apoyo, cariño y comprensión (y bajadas a tierra también), y a mi hijo Jaime porque a pesar de ser totalmente ajeno a todo este proceso ha sido fuente inagotable de alegría. Empecé la tesis a los pocos meses de ser padre por lo que todo este proceso ha sido también un proceso familiar y ha supuesto la ilusión y la esperanza en un futuro mejor en muchos sentidos. Curiosamente, hacer la tesis ha ido acompañado de una cierta desconexión con el mundo laboral del que provengo, de una conexión (casi una reinserción) en el mundo académico y de un tiempo inusual hoy en día para disfrutar de mi familia.

También quiero agradecer el apoyo recibido por parte de mi familia y de la familia de mi mujer. Y a los amigos que siempre han creído más en mis posibilidades frente a una tesis que yo mismo: Carlos Fernández, Tim Appleton, Jon Subinas y Alberto Sanz, entre otros.

# ÍNDICE

ÍNDICE .....	v
ÍNDICE DE TABLAS .....	viii
ÍNDICE DE FIGURAS .....	x
LISTADO ALFABÉTICO DE ACRÓNIMOS .....	xii
 RESUMEN .....	 xv
 ABSTRACT .....	 xvii
 PRÓLOGO .....	 I
 CAPÍTULO 1: Alcance y contextos de aplicación del AFC. Delimitación del problema.....	 2
1.1. Modelos causales de medida: conceptos básicos .....	5
1.2. AFC como caso particular de investigación no experimental .....	22
1.3. Recomendaciones sobre AFC en contextos aplicados. ....	37
1.4. Evidencias sobre la varianza común de las variables latentes: <i>clústers</i> independientes y modelo de independencia.....	61
1.4.1. Uso generalizado de índices de ajuste del modelo multidimensional .....	61
1.4.2. Tipo de error de especificación y sensibilidad de los índices descriptivos de bondad de ajuste .....	67
1.4.3. Evaluación del modelo de independencia como fuente de evidencia.....	72
 CAPÍTULO 2: Diseño de la investigación: estudio de simulación Monte Carlo .....	 81
2.1. Modelos y condiciones simuladas .....	82
2.2. Procedimiento de simulación y estimación: PRELIS 2.0 y LISREL 8.8 .....	91
2.2.1. Métodos de estimación .....	92
2.2.2. Selección de variables dependientes .....	96

CAPÍTULO 3: Resultados .....	103
3.1. ESTUDIO 1: datos continuos .....	104
3.1.1. Problemas de convergencia y casos <i>Heywood</i> .....	104
3.1.2. Modelo de independencia y calidad en la recuperación de parámetros.....	107
3.1.3. Modelo de independencia e índices descriptivos de ajuste.....	113
3.2. ESTUDIO 2: datos ordinales y dicotómicos .....	122
3.2.1. Problemas de convergencia y casos <i>Heywood</i> .....	122
3.2.2. Modelo de independencia y calidad en la recuperación de parámetros.....	132
3.2.3. Modelo de independencia e índices descriptivos de ajuste.....	145
3.3. Aproximación a los estudios de potencia .....	152
 CAPÍTULO 4: Discusión y conclusiones .....	 163
 REFERENCIAS .....	 179
 ANEXOS.....	 191
A. Ejemplos de sintaxis .....	191
B. Datos continuos (distribución normal).....	192
Ficha 1. Modelos simulados y síntesis de resultados ( $n = 4$ ) .....	192
Ficha 2. Modelos simulados y síntesis de resultados ( $n = 5$ ) .....	194
Ficha 3. Modelos simulados y síntesis de resultados ( $n = 6$ ) .....	196
Ficha 4. Modelos simulados y síntesis de resultados ( $n = 7$ ) .....	198
Ficha 5. Modelos simulados y síntesis de resultados ( $n = 15$ ) .....	200
C. Datos ordinales (5 categorías).....	202
Ficha 6. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3, n = 4$ ) .....	203
Ficha 7. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3, n = 5$ ) .....	207
Ficha 8. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3, n = 6$ ) .....	211
Ficha 9. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,4, n = 4, 5, 6$ ) .....	215
D. Datos dicotómicos .....	219
Ficha 10. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3, n = 4$ ) .....	220
Ficha 11. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3, n = 5$ ) .....	224
Ficha 12. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3, n = 6$ ) .....	228

Ficha 13. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,4$ , $n = 4, 5, 6$ ) .....	232
E. Estudios adicionales .....	236
Ficha 14. Factores compuestos por $n = 3$ variables observables ( $\lambda_{ij} = 0,3, 0,4$ y $0,5$ )	236
Ficha 15. Niveles heterogéneos de $\lambda_{ij}$ , $n = 4$ .....	238
Ficha 16. Niveles heterogéneos de $\lambda_{ij}$ , $n = 5$ .....	242
F. Promedio de las cargas factoriales estimadas.....	246
F.1. Datos continuos (estimación ML) .....	246
F.2. Datos ordinales – 5 categorías ( $\lambda_{ij} = 0,3$ ; estimación RDWLS) .....	249
F.3. Datos dicotómicos ( $\lambda_{ij} = 0,3$ ; estimación RDWLS).....	252

## ÍNDICE DE TABLAS

Tabla 1. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ , $RMSD_j$ , $ARB_j$ y $AMSE_j$ ) .....	108
Tabla 2. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ , $RMSD_j$ , $ARB_j$ y $AMSE_j$ ): niveles heterogéneos de lambda ( $\lambda_{Het.}$ ) .....	111
Tabla 3. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ , $RMSD_j$ , $ARB_j$ y $AMSE_j$ ) .....	132
Tabla 4. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ , $RMSD_j$ , $ARB_j$ y $AMSE_j$ ): niveles heterogéneos de lambda ( $\lambda_{Het.}$ ). .....	136
Tabla 5. Comparación de la proporción de soluciones IM, T1 y T2 y del valor promedio de $C_j$ en función de los datos simulados: nivel fijo de lambda ( $\lambda_{ij} = 0,3$ ).....	140
Tabla 6. Comparación de la proporción de soluciones IM, T1 y T2 y del valor promedio de $C_j$ en función de los datos simulados: cargas heterogéneas.....	141
Tabla 7. Estadísticos descriptivos de los índices CFI, $ECVI_r$ y $CAIC_r$ dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Nivel fijo de lambda ( $\lambda_{ij} = 0,3$ ), $n = 4$ .....	147
Tabla 8. Estadísticos descriptivos de los índices CFI, $ECVI_r$ y $CAIC_r$ dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Nivel fijo de lambda ( $\lambda_{ij} = 0,3$ ), $n = 5$ .....	149
Tabla 9. Estadísticos descriptivos de los índices CFI, $ECVI_r$ y $CAIC_r$ dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Cargas heterogéneas ( $n = 4$ ) .....	150
Tabla 10. Estadísticos descriptivos de los índices CFI, $ECVI_r$ y $CAIC_r$ dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Cargas heterogéneas ( $n = 5$ ) .....	151
Tabla 11. Resultados obtenidos en relación a los estudios de potencia con datos continuos. Nivel fijo de lambda ( $\lambda_{ij} = 0,3$ ), $n = 4$ , estimación ML.....	154
Tabla 12. $n = 4$ (entre paréntesis el valor poblacional de lambda para cada $x_i$ ) .....	156
Tabla 13. $n = 5$ (entre paréntesis el valor poblacional de lambda para cada $x_i$ ) .....	156



Tabla 14. Resultados obtenidos en relación a los estudios de potencia con datos ordinales. Nivel fijo de $\lambda_{ij} = 0,3$ , $n = 5$ , distribución simétrica (5D1), estimación RDWLS .....	158
Tabla 15. Resultados obtenidos en relación a los estudios de potencia con datos ordinales. Nivel fijo de $\lambda_{ij} = 0,4$ , $n = 5$ , distribución asimétrica (5D2), estimación RDWLS.....	159
Tabla 16. Resultados obtenidos en relación a los estudios de potencia con datos ordinales. Cargas heterogéneas, $n = 5$ , distribución simétrica (5D1), estimación RDWLS .....	160
Tabla 17. Resultados obtenidos en relación a los estudios de potencia con datos dicotómicos. Nivel fijo de $\lambda_{ij} = 0,3$ , $n = 6$ , distribución simétrica (2D1), estimación RDWLS.....	161

## ÍNDICE DE FIGURAS

Figura 1. Diagrama sobre la práctica convencional en el uso de SEM (Kaplan, 2008) .....	29
Figura 2. Modelos AFC teóricos (poblacionales) utilizados en los estudios de simulación .....	84
Figura 3. Número de categorías discretas y tipo de distribución de los datos simulados a partir de los datos continuos originales .....	85
Figura 4. Proporción de soluciones IM (datos continuos).....	105
Figura 5. Proporción de soluciones IM (datos continuos, $\lambda_{ij}$ heterogéneas) .....	106
Figura 6. Promedio de $C_j$ por tipo de solución (T1-T2). Datos continuos (ML).....	110
Figura 7. Promedio de $C_j$ por tipo de solución (T1-T2). Datos continuos (ML), cargas heterogéneas	112
Figura 8. Promedio nivel crítico de $\chi^2_0$ en función del test $\chi^2_{Null}$ . Datos continuos, estimación ML..	115
Figura 9. Promedio de CFI en función del test $\chi^2_{Null}$ . Datos continuos, estimación ML.....	118
Figura 10. Promedio de $ECVI_r$ en función del test $\chi^2_{Null}$ . Datos continuos, estimación ML.....	120
Figura 11. Promedio de $CAIC_r$ en función del test $\chi^2_{Null}$ . Datos continuos, estimación ML.....	121
Figura 12. Proporción de soluciones IM (datos ordinales: 5 categorías, $\lambda_{ij} = 0,3$ ).....	123
Figura 13. Proporción de soluciones IM (datos ordinales: 5 categorías, $\lambda_{ij} = 0,4$ ).....	124
Figura 14. Proporción de soluciones IM (datos dicotómicos, $\lambda_{ij} = 0,3$ ).....	125
Figura 15. Proporción de soluciones IM (datos dicotómicos, $\lambda_{ij} = 0,4$ ).....	126
Figura 16. Proporción de soluciones IM (datos ordinales: 5 categorías, $\lambda_{ij} =$ heterogéneas).....	127
Figura 17. Proporción de soluciones IM (datos dicotómicos, $\lambda_{ij}$ heterogéneas) .....	128
Figura 18. Proporción de soluciones IM (datos ordinales: 5 categorías, $n = 3$ ) .....	130

Figura 19. Proporción de soluciones IM (datos dicotómicos, $n = 3$ ).....	131
Figura 20. Promedio de $C_j$ por tipo de solución (T1-T2). Datos ordinales; RDWLS .....	134
Figura 21. Promedio de $C_j$ por tipo de solución (T1-T2). Datos dicotómicos; RDWLS .....	135
Figura 22. Promedio de $C_j$ por tipo de solución (T1-T2). Datos ordinales; $\lambda_{ij}$ heterogéneas; RDWLS .....	137
Figura 23. Promedio de $C_j$ por tipo de solución (T1-T2). Datos dicotómicos; $\lambda_{ij}$ heterogéneas; RDWLS .....	138
Figura 24. Promedio de los índices de ajuste teórico en la condición $n = 3$ . Datos ordinales.....	143
Figura 25. Promedio de los índices de ajuste teórico en la condición $n = 3$ . Datos dicotómicos.....	144

## LISTADO ALFABÉTICO DE ACRÓNIMOS

(R)DWLS	Método de estimación ( <i>Robust</i> ) <i>Diagonal Weighted Least Squares</i>
(R)ML	Método de estimación ( <i>Robust</i> ) <i>Maximum Likelihood</i>
(R)ULS	Método de estimación ( <i>Robust</i> ) <i>Unweighted Least Squares</i>
*.ACP	Extensión del archivo que contiene las matrices asintóticas de varianzas-covarianzas
*.GF	Extensión del archivo que contiene los índices de ajuste descriptivo (entre otros) que se obtienen tras ajustar modelos AFC mediante LISREL
*.PV	Extensión del archivo que contiene los parámetros estimados mediante LISREL
*.RAW	Extensión del archivo que contienen los datos brutos que utiliza PRELIS para calcular la matriz asintótica de varianzas-covarianzas con datos discretos
*.SV	Extensión del archivo que contiene los errores de estimación que se obtienen tras ajustar modelos AFC mediante LISREL
2D1	Condiciones simuladas a partir de datos dicotómicos y distribución simétrica
2D2	Condiciones simuladas a partir de datos dicotómicos y distribución ligeramente asimétrica
2D3	Condiciones simuladas a partir de datos dicotómicos y distribución con fuerte asimetría
5D1	Condiciones simuladas a partir de datos ordinales (5 categorías) y distribución simétrica
5D2	Condiciones simuladas a partir de datos ordinales (5 categorías) y distribución con fuerte asimetría
5D3	Condiciones simuladas a partir de datos ordinales (5 categorías) y distribución uniforme
AF	Análisis Factorial
AFC	Análisis Factorial Confirmatorio
AFE	Análisis Factorial Exploratorio
AIC	<i>Akaike Information Criterion</i>
AM	<i>Alternative Models</i> . Escenario prototípico propuesto por Jöreskog

$AMSE_j$	<i>Average Root Mean Square Error</i>
ANCOVA	Análisis de covarianza
ANOVA	Análisis de varianza
AP	Análisis paralelo
APA	<i>American Psychological Association</i>
$ARB_j$	<i>Average Relative Bias</i>
BL89	<i>Incremental Fit Index</i> (Bollen)
CAIC	<i>Consistent Akaike Information Criterion</i>
CFI	<i>Comparative Fit Index</i> (versión normalizada de RNI)
$C_j$	Coefficiente de congruencia
COV	Covarianza
det	Determinante
E/CFA	<i>Exploratory/Confirmatory Factor Analysis</i> . Análisis Factorial Exploratorio en el marco del Análisis Factorial Confirmatorio
ECVI	<i>Expected Cross-Validation Index</i>
ESEM	<i>Exploratory SEM</i> . Modelos de ecuaciones estructurales exploratorios
IFI	<i>Incremental Fit Index</i>
IM	Soluciones impropias: soluciones no convergentes y/o con presencia de casos Heywood
JAP	<i>Journal of Applied Psychology</i>
JPSP	<i>Journal of Personality and Social Psychology</i>
LISREL	<i>Linear Structural Relations</i> . Paquete de <i>software</i> estadístico
MAP	<i>Minimum Average Partial</i>
Mc	<i>Measure of Centrality index</i>
MG	<i>Model Generation</i> . Escenario prototípico propuesto por Jöreskog
MI	Índices de modificación
MIMIC	<i>Multiple Indicators Multiple Causes</i>
MTMM	Matriz multirasgo-multimétodo

NNFI (TLI)	<i>Non-Normed Fit Index (Tucker-Lewis Index)</i>
PRELIS	Módulo de preparación de datos incluido en el paquete LISREL
PsychINFO	<i>American Psychological Association</i> database
RFI	<i>Relative Fit Index</i>
$RMSD_j$	<i>Root Mean Square Deviation</i>
RMSEA	<i>Root Mean Square Error of Approximation</i>
RNI	<i>Relative Noncentrality Index</i>
RPP	Revisión de las prácticas de publicación de modelos de Análisis Factorial
SC	<i>Strictly confirmatory</i> . Escenario prototípico propuesto por Jöreskog
SEM	<i>Structural Equation Modeling</i>
SRMR	<i>Standardized Root Mean Square Residual</i>
T1	Soluciones en las que se ha rechazado la $H_0$ del modelo de independencia
T2	Soluciones en las que se mantiene la $H_0$ del modelo de independencia
VCL (factor)	Factores con varianza común limitada
VD	Variable dependiente
VI	Variable independiente

## RESUMEN

La aplicación de puntos de corte en los valores de las cargas factoriales estimados ( $\hat{\lambda}_{ij}$ ) para seleccionar/eliminar variables observables cuando se utiliza Análisis Factorial (AF) y Modelos de Ecuaciones Estructurales (SEM) es una cuestión sin resolver. Si bien existen varias recomendaciones, no existe acuerdo sobre cuáles deben ser estos valores de corte, estando fuertemente condicionados por el alcance y los objetivos de cada contexto de investigación. Algunos autores recomiendan utilizar valores de corte de 0,7 frente a otros que recomiendan valores de 0,3 como cargas factoriales salientes. Desde un punto de vista teórico, la exclusión arbitraria de variables observables puede derivar en la infrarrepresentación del constructo evaluado. Esta situación es más problemática cuando un determinado factor está representado por distintas variables observables con cargas bajas, lo que produce factores que acumulan una cantidad limitada o nula de varianza común.

La revisión de las prácticas de publicación ha mostrado que buena parte de los análisis realizados en investigación aplicada se han desarrollado en condiciones pobres o subóptimas. Por lo tanto, es razonable considerar que el problema no tiene que centrarse necesariamente en el constructo hipotético, sino en la evaluación de la sensibilidad de la técnica estadística. En el presente trabajo se han simulado estructuras unifactoriales a partir de variables observables con cargas bajas en la población ( $\lambda_{ij}$ ) bajo ciertas condiciones. En primer lugar, cada factor simulado se analizó mediante Análisis Factorial Confirmatorio (AFC). En segundo lugar, se evaluó la sensibilidad de la técnica para detectar factores que son verdaderos en la población mediante la *prueba  $\chi^2$  del modelo de independencia* ( $\chi^2_{\text{Null}}$ ), bajo la hipótesis nula de que la matriz de varianzas-covarianzas ( $\Sigma$ ) es diagonal (es decir, que todas las variables observables que

dependen de un mismo factor no están correlacionadas). Se ha elaborado un estudio Monte Carlo (496 condiciones, 1.000 réplicas por condición), asumiendo que cada modelo unifactorial simulado es un *clúster independiente*, formado por diferentes magnitudes de carga factorial en la población ( $\lambda_{ij} = 0,2, 0,3, 0,4$ ), número de variables observables por factor ( $n = 4, 5, 6, 7, 15$ ), tamaño muestral ( $N = 200, 300, 400, 500$ ), tipo de datos (continuos, ordinales y dicotómicos), tipo de distribución (simétrica, asimétrica, uniforme), y utilizando cinco métodos de estimación diferentes (ML, ULS, RDWLS, RML y RULS). Los resultados muestran que la capacidad del AFC para detectar factores verdaderos en la población que presentan cargas bajas requiere de condiciones más exigentes que las que muestra la práctica convencional, especialmente ante la existencia de asimetría y con datos dicotómicos. Cuando se rechaza  $H_0$  del modelo de independencia se observan discrepancias más pequeñas entre los parámetros estimados y los simulados, encontrando que ECVI, AIC y CAIC funcionan como índices de aproximación más eficaces que los que se utilizan en la práctica habitual como RMSEA, SRMR, NNFI o CFI.



## ABSTRACT

The application of cutoff value of estimated factor loadings ( $\hat{\lambda}_{ij}$ ) to select/eliminate observed variables conducting Factor Analysis (FA) and Structural Equation Models (SEM) is an unresolved issue. While there are several recommendations, there is no agreement on these cutoff values, being strongly conditioned by the scope and objectives of each research context. Some authors recommend a cutoff of .7 against others who recommend .3 values as salient factor loadings. From a theoretical point of view, the arbitrary exclusion of observed variables may result in construct underrepresentation. This situation is more problematic when a certain factor is represented by several observed variables with low loadings, resulting in factors that aggregate a limited or null account of common variance.

The reporting practices revision has shown that most of the analysis conducted in applied research have been developed in poor or suboptimal conditions. Therefore, it is reasonable to argue that the problem should not necessarily focus on the hypothetical construct, but in the evaluation of the sensitivity of the statistical technique. To achieve this goal, in this work we have been simulated unifactorial structures from observed variables with low population loadings ( $\lambda_{ij}$ ) under different kind of conditions. First, each simulated factor was analyzed conducting Confirmatory Factor Analysis (CFA). After that, the sensitivity of the technique to detect factors that are true in the population was evaluating by *testing  $\chi^2$  of the independence model* ( $\chi^2_{\text{Null}}$ ), under the null hypothesis that the variances-covariances matrix ( $\Sigma$ ) is diagonal (i.e., all the observed variables that depend on the same factor are uncorrelated). We performed a Monte Carlo study (496 conditions, 1,000 replications per condition), assuming each unifactorial simulated model as an *independent cluster*, with different magnitudes of population

factor loading ( $\lambda_{ij} = .2, .3, .4$ ), number of observed variables per factor ( $n = 4, 5, 6, 7, 15$ ), sample size ( $N = 200, 300, 400, 500$ ), type of data (continuous, ordinal and dichotomous), type of distribution (symmetrical, asymmetrical, uniform) and using five different methods of estimation (ML, ULS, RDWLS, RML y RULS). The results show that the CFA ability to detect true factors with low loadings requires more stringent conditions than those shown in common practice, especially in asymmetric distributions and dichotomous data. Smaller discrepancies between the simulated and the estimated parameters are obtained when  $H_0$  of the independence model is rejected. ECVI, AIC and CAIC have better performance as approximation indices than those that are used more frequently (RMSEA, SRMR, NNFI and CFI).

## PRÓLOGO

Mi trayectoria como metodólogo durante los últimos 15 años ha sido claramente más profesional que académica. En este período de tiempo no han sido pocas las veces que he trabajado con datos aplicados, y de todo tipo. Al tener un perfil transversal, mi currículum profesional abarca la participación en proyectos relacionados con la investigación en psicología, los estudios sociológicos y politológicos, el análisis de datos en economía aplicada, la consultoría interna y externa, y la evaluación de programas, entre otros.

La variedad de instrumentos de medida con la que he trabajado ha sido amplia. En algunos casos las herramientas utilizadas ya existían previamente (con mayor o menor grado de validación y de estandarización), mientras que en otros estudios mi labor arrancaba con el diseño muestral y con la redacción de los ítems de diferentes tests y cuestionarios. También las aplicaciones en las que he participado variaron en cuanto a modalidad: desde cuestionarios y tests *on-line* dirigidos a enormes muestras de consumidores y no consumidores en estudios de mercado, a la aplicación en calle (o en domicilio) a través de la mediación de entrevistadores profesionales. En varias ocasiones su aplicación se sustentó en un diseño muestral de tipo probabilístico de ámbito nacional mientras que, en otras, los análisis debían ser realizados tras obtener muestras pequeñas o muy pequeñas mediante muestreo no probabilístico. La mayoría de las veces el objetivo de estas aplicaciones era de carácter instrumental ya que, tras analizar la información descriptiva directa y varias de las características psicométricas más comunes, se utilizaban las puntuaciones de los sujetos en análisis complementarios. Otras veces los objetivos se centraron en la validación de las propias herramientas utilizadas, aunque este tipo de estudios es el menos frecuente en mi experiencia.

En la mayoría de estos estudios apliqué Análisis Factorial (AF), especialmente Análisis Factorial Exploratorio (AFE). A veces apliqué Análisis Clúster sobre variables y sobre casos y Análisis Multidimensional como alternativas al AF en determinadas situaciones. Solamente apliqué Análisis Factorial Confirmatorio (AFC) en contadas ocasiones. Hasta la fecha no he realizado ningún Modelo de Ecuaciones Estructurales (SEM) por encargo. Por último, en una ocasión tuve la oportunidad de trabajar con modelos de TRI, aplicándolos a datos de rendimiento académico recogidos en muestras grandes (Informe PISA: Educación Primaria 2009).

A pesar de la variedad de aplicaciones y de contextos, una de las situaciones que tuve que enfrentar en muchos de estos estudios fue la falta de una teoría subyacente a los datos, al menos en un sentido científico fuerte. Estas carencias teóricas me llevaron a tomar un buen número de decisiones analíticas de manera heurística, tratando de buscar aquel resultado que mejor combinase las garantías técnicas de los modelos con las expectativas puestas en los análisis por parte de mis clientes. Este encaje entre garantías técnicas y expectativas no es siempre fácil de conseguir, menos todavía en un contexto en donde está muy instaurada la creencia de que los modelos estadísticos son la realidad, y en donde es habitual que las expectativas de los clientes internos difieran de las expectativas de los clientes externos. Llegado a cierto punto me di cuenta de que me estaba estancando a nivel profesional. Cada vez me resultaba menos satisfactorio recurrir a “las fórmulas de siempre” para justificar, advertir o explicitar por qué determinados aspectos de los modelos no funcionan bien, incluso nada bien, y “torturar” a los datos (como se dice en el argot) hasta que el resultado encajase en las expectativas previas. Es entonces cuando decido retomar mis estudios de doctorado, que había pospuesto años atrás principalmente por mi incorporación al mercado laboral, matriculándome en el Master en el curso académico 2010/2011.

El presente trabajo de tesis sigue una línea marcada desde el Trabajo de Fin de Master (TFM) defendido en septiembre de 2012, aunque ha sufrido importantes cambios de enfoque que comentaré en estas páginas. En este sentido, la colaboración con el profesor Jesús M<sup>a</sup> Alvarado ha sido muy estrecha y fructífera. Se inició siendo su alumno en la asignatura del Master sobre Validez, luego se materializó en la dirección del TFM y actualmente en la dirección del presente trabajo de tesis. Durante la impartición de la asignatura de Validez un tema de especial interés fue la evaluación de la dimensionalidad de los instrumentos de medición. Obviamente, esta cuestión no es exclusiva de esta asignatura dentro del Master ya que en otras asignaturas se trabajan los aspectos teóricos y prácticos del AF, la TRI y otras técnicas. No obstante, al menos desde mi punto de vista, esta asignatura es el único espacio dentro del Master en donde se prueban los límites de dicha evaluación, donde se problematiza la cuestión de la dimensionalidad de forma crítica y en donde, lógicamente, el *gap* entre teoría y práctica se hace más patente.

Llegado el momento de plantear un tema para el TFM, debo reconocer que no tenía un plan claro de investigación, una temática concreta por así decir, lo que sí tenía claro es de dónde venía y el tipo de problemas y de limitaciones que enfrentaba habitualmente en la práctica profesional. Dentro de esta práctica, una cuestión recurrente que debía abordar era que en muchos estudios parte de los instrumentos de medida, ciertos ítems, que se suponía debían medir aspectos sustantivos del objeto evaluado no se comportaban como se esperaba, y no siempre por la sempiterna cuestión del tamaño muestral. Existen varias recomendaciones sobre qué hacer ante la aparición de ítems que no se comportan de manera óptima, por ejemplo, cuando existen problemas de fiabilidad. Podríamos dividir estas recomendaciones en dos grandes grupos: el primero, hace referencia al tipo de recomendaciones encaminadas a aumentar el número de observaciones y/o el número de variables observables. En el marco de

trabajo del AF, la literatura utiliza la expresión “número de variables observables por factor”,  $p/f$  o  $p/k$  (en este trabajo se utiliza la expresión simplificada  $n$ , diferenciándola del número de observaciones o  $N$ ). El segundo grupo de recomendaciones hace referencia a la eliminación de contenido irrelevante estadísticamente, a la “poda” del constructo, eliminando aquellas variables observables o factores que reflejan un mal comportamiento psicométrico en el proceso de selección, o bajas cargas factoriales estimadas tras la aplicación del AF. Desde un punto de vista exploratorio, siempre he sido partidario de aplicar alguna de estas recomendaciones, pero su aplicación práctica no siempre es evidente y no está exenta de problemas y de limitaciones. Así, dentro de mi experiencia profesional, en la mayoría de aplicaciones no hay posibilidad de “volver hacia atrás” para aumentar  $N$  y/o  $n$ . Los estudios en los que he participado cuentan solamente con una muestra y siempre hay un contrato que resolver (con limitaciones importantes de tiempo), por lo que aplicar este tipo de recomendaciones no resulta posible. Estas cuestiones deberían ser tratadas y comprendidas desde el propio diseño de la investigación, esto es, antes de recoger los datos, y los distintos resultados deberían replicarse en nuevas muestras. Desgraciadamente, estas cuestiones son más un ideal que un estándar en la práctica. Por otro lado, eliminar ítems o factores que no se comportan de manera adecuada no resulta satisfactorio en el momento en el que la poda del constructo evaluado implica eliminar elementos sustantivos, incluso los más sustantivos respecto a los objetivos de un determinado estudio. ¿Cómo justificar la eliminación de partes del constructo que deberían permitir incidir en alguno de los objetivos clave dentro de un estudio presupuestado y con calendario de ejecución? En mi experiencia, esta disonancia o desajuste ha supuesto un reto importante en no pocas ocasiones. Una posibilidad es cambiar la estrategia de análisis y reducir el alcance de la investigación, realizando análisis estadísticos de “perfil más bajo”, aunque este margen de maniobra pocas veces está bien visto.

En base a lo anterior, la conexión de mis inquietudes profesionales con la asignatura de Validez era más que evidente, solo faltaba ya concretar una línea de investigación sobre la que poder trabajar. Es en este punto en el que debo mencionar la importancia de los trabajos de la profesora Carmen Ximénez sobre recuperación de factores débiles (Ximénez, 2006, 2007, 2009 y 2016). Un factor débil se define como un factor que muestra tener poca influencia en el conjunto de variables observables, lo que se refleja en la presencia de cargas factoriales bajas tras el proceso de estimación ( $\hat{\lambda}_{ij}$ ). Fue aquí por primera vez donde empecé a ver reflejadas mis inquietudes profesionales en los trabajos que provienen del mundo académico. Estos trabajos no solo me ayudaron a elegir el tema a desarrollar en el TFM, sino que fueron también un inestimable marco metodológico y procedimental para elaborar el trabajo de simulación y posterior evaluación de resultados, más teniendo en cuenta que los programas utilizados son los poco amigables PRELIS y LISREL (Jöreskog y Sörbom, 1996a, 1996b). Los trabajos de la profesora Ximénez han puesto de manifiesto una cuestión muy relevante desde el punto de vista aplicado y es que determinados factores que presentan cargas estimadas bajas pueden suponer estimaciones precisas de los parámetros en la población, aunque lógicamente no en la misma proporción que aquellos factores con cargas estimadas más altas. Estos resultados ponen en evidencia que la eliminación “ciega” de contenido relevante mediante la aplicación de ciertos puntos de corte sobre el valor de las cargas estimadas tal vez no sea siempre una estrategia adecuada, más todavía en el marco de trabajo del AFC que es donde la profesora Ximénez ha desarrollado sus estudios. Estos resultados se obtuvieron a partir de modelos correctamente especificados, con y sin correlación entre factores (Ximénez, 2006, 2007) y a partir de modelos incorrectamente especificados, por ejemplo omitiendo la especificación de uno de los factores del modelo teórico (Ximénez, 2009).

Estudios sistemáticos sobre la recuperación de los parámetros de este tipo de factores que presentan  $\hat{\lambda}_{ij}$  bajas se pueden encontrar tanto en el marco del AFE como en el marco del AFC. En estos estudios se han simulado datos muestrales a partir de estructuras factoriales con cargas poblacionales ( $\lambda_{ij}$ ) consideradas como bajas por los diferentes autores. En el marco del AFE, las magnitudes simuladas más pequeñas de  $\lambda_{ij}$  en los diferentes estudios han sido de 0,5 (MacCallum, Tucker, y Briggs, 2001), 0,4 (Briggs y MacCallum, 2003), y 0,2 (MacCallum, Widaman, Zhang, y Hong, 1999; Mundfrom, Shaw, y Ke, 2005; De Winter, Dodou, y Wieringa, 2009). En el marco del AFC, las magnitudes simuladas más pequeñas de  $\lambda_{ij}$  han sido 0,5 (Wolf, Harrington, Clark, y Miller, 2013), 0,4 (Enders y Bandalos, 2001), entre 0,3 y 0,4 (Heene, Hilbert, Draxler, Ziegler, y Bühner, 2011, Ximénez, 2009, 2016), 0,25 (Ximénez, 2006, 2007), y 0,2 (Gagné y Hancock, 2006).

Aunque existen importantes diferencias entre estos estudios (diferentes objetivos, complejidad de los modelos simulados, elección de variables dependientes, etc.), todos ellos se fundamentan en la variación de los niveles de, al menos, dos de las siguientes variables independientes: moderada o baja magnitud de  $\lambda_{ij}$ ,  $n$  y  $N$ . En aquellos estudios en los que se simularon dos de estas variables, se evaluó el efecto combinado de la magnitud de  $\lambda_{ij}$  y del número de observaciones. Otra característica común a todos estos estudios es que todas las simulaciones y evaluaciones se realizaron sobre datos continuos. En el TFM se siguió este tipo de diseños dentro del marco de trabajo del AFC, a partir principalmente de los trabajos previos de la profesora Ximénez hasta 2007. La mayor parte de las referencias citadas más arriba fueron revisadas y añadidas más tarde, para la elaboración del presente trabajo de tesis.

Una vez presentado y defendido el TFM, varias son las cuestiones a considerar para precisar y entender cuáles han sido los principales cambios de enfoque que sustentan el trabajo



de tesis. En este sentido, varias son las lecturas que se han ido incorporando tras el TFM y que han permitido reorientar el objeto de estudio de la tesis. Especialmente relevante ha sido la lectura del capítulo 13 *How to Fool Yourself with SEM* del manual de Kline (2010). Por alguna razón que desconozco, este capítulo ya no aparece en la siguiente edición del 2015, aunque esta edición vuelve a tratar las mismas problemáticas. Tal vez la línea editorial consideró que este material era demasiado confrontador, directo o incluso irónico para un manual de estas características. También ha sido una importante fuente de inspiración la idea del centroide del constructo desarrollada por Little, Lindenberger, y Nesselroade (1999), que incorpora la necesidad de analizar la heterogeneidad o diversidad de las variables observables como criterio a la hora de evaluar constructos, evitando así evaluaciones “ciegas” a su contenido. Apoyándome en estas lecturas y reflexiones, entre otras, en el presente trabajo de tesis se ha utilizado el término *factor con varianza común limitada* (factor VCL) para referir a aquellos factores que presentan cargas estimadas bajas. Este cambio de término conlleva algunas implicaciones conceptuales que considero importantes. En primer lugar, en el presente trabajo no existe un posicionamiento *a priori* sobre si los factores que evalúa el investigador aplicado son fuertes o débiles, bajo la consideración de que esta cuestión implica a las teorías subyacentes propias de cada contexto de aplicación. A mi juicio tiene más sentido hablar de investigación débil o fuerte respecto a las condiciones en las que se aplica AF, al igual que ocurre en Psicometría cuando se abordan los problemas de la medición (Lord y Novick, 1968). En segundo lugar, supone la forma de compartimentar o acotar los objetivos a estudiar. La presencia o ausencia de varianza común en los modelos AF es un requisito previo que recibió en su día mucha atención en el marco de trabajo del AFE. La evaluación de la factorabilidad en AFE (*factorability* en inglés) se realiza a partir de dos métodos clásicos: el indicador de factorabilidad Kaiser-Meyer-Oblim o KMO y la prueba de esfericidad de Bartlett. Estos

métodos están actualmente en desuso ya que, por regla general, es muy sencillo cumplir con los criterios establecidos cuando se aplican sobre modelos multidimensionales, más o menos extensos. No obstante, la cuestión de la factorabilidad cobra nueva vida cuando el problema de investigación implica la evaluación de la consistencia empírica de factores VCL.

En tercer lugar, el marco de trabajo utilizado para evaluar la factorabilidad ha sido el del AFC. En este sentido, conviene señalar que los procedimientos utilizados en todo el trabajo de simulación son muy similares a los trabajos revisados y al TFM, aunque conceptualmente distintos. Evaluar hasta qué punto existe varianza común suficiente es un requisito que debe cumplirse antes de evaluar la calidad de la recuperación de parámetros dado que si no hay varianza común no tiene sentido continuar con el análisis. Esta estrategia de análisis se ha denominado como pre-evaluación en el presente trabajo, y ambos tipos de estudios pueden considerarse como complementarios. Si se me permite la licencia, si estuviésemos hablando de una película, la evaluación de la factorabilidad sería la precuela. El marco del AFC tiene la ventaja de implementar en el software estadístico información que no está disponible en el marco del AFE. Entre dicha información contamos con el valor de  $\chi^2$  del modelo nulo o de independencia, que es el estadístico que se ha utilizado para poner a prueba la existencia de factorabilidad, esto es, la prueba  $\chi^2_{\text{Null}}$  permite realizar inferencias sobre la  $H_0$  de que la relación entre las variables observables es cero (Jöreskog, 2004; Jöreskog y Sörbom, 1993; Mulaik, 2009). Además, el marco del AFC permite retomar aspectos importantes en ciencia como el concepto de causalidad y las estrategias *theory-driven*, al tratarse de una estrategia de análisis confirmatoria. Desde esta perspectiva, el investigador no se encuentra casualmente con factores VCL, sino que los evalúa y somete a prueba en tanto que hipótesis sustantivas.

En cuarto lugar, y en relación al aspecto tal vez más relevante de todo el trabajo, la evaluación de la factorabilidad se ha realizado asumiendo el aislamiento del factor VCL, es

decir, a partir de la simulación de estructuras unifactoriales. Esta forma de proceder pretende simular una estrategia de pre-evaluación a la evaluación del modelo completo (multidimensional), y se sustenta tanto en el concepto de *clústers independientes* (McDonald, 1999; McDonald y Ho, 2002), como en la estrategia de evaluación propuesta por Jöreskog y Sörbom (1993) para la generación de modelos. Hasta donde conozco, no existe en la literatura previa antecedentes de este tipo de pre-evaluación del modelo de independencia.

Para terminar de completar este esbozo sobre el desarrollo de la tesis, señalaré otras lecturas de especial relevancia. En relacionan a la falta de sensibilidad de los índices de bondad de ajuste ante la presencia de sobreparametrización, ha sido fundamental la lectura del trabajo de Heene et al. (2011), lo que ha llevado a evaluar y proponer otros índices de aproximación en este trabajo, como *Expected Cross-Validation* o ECVI (Jöreskog y Sörbom, 1993). Sobre incluir la importancia del concepto de potencia en AF y la evaluación de cargas factoriales heterogéneas destacar el trabajo de De Winter et al. (2009), y el trabajo de Gagné y Hancock (2006) sobre la relación entre fiabilidad y convergencia de la estimación como índice de calidad. También es preciso señalar que, si bien se parte de la simulación de datos ideales, esto es, datos continuos, los resultados más relevantes se han obtenido en la evaluación de las soluciones estimadas a partir de datos ordinales (5 categorías) y dicotómicos. Para la simulación, estimación y evaluación de este último tipo de datos ha resultado imprescindible la lectura del trabajo de Forero, Maydeu-Olivares, y Gallardo-Pujol (2009) y, especialmente, la del trabajo de Yang-Wallentin, Jöreskog, y Lou (2010) cuyo anexo facilita información muy útil sobre la sintaxis a utilizar con PRELIS y LISREL.



# CAPÍTULO 1

Alcance y contextos de aplicación del AFC.

Delimitación del problema

## CAPÍTULO 1: Alcance y contextos de aplicación del AFC. Delimitación del problema

Desde que Jöreskog y Lawley (1967) y Jöreskog (1969) propusieron el modelo general del AFC, el tipo de aplicaciones que se han desarrollado con esta herramienta en diversos contextos de investigación ha sido enorme. En el Capítulo 1 se introducen los elementos considerados como nucleares dentro de este amplio marco de trabajo con el fin de justificar y delimitar el objeto de estudio. Generalmente, se suelen identificar los modelos AFC como un caso particular y especial dentro del marco de trabajo de los métodos de investigación no experimentales, ya que permiten explicar fenómenos y poner a prueba teorías, más allá de la descripción y análisis de patrones de relación entre variables, si bien su aplicación (en la mayoría de los casos) se realiza a partir de datos que provienen de contextos en los que no existe manipulación experimental ni asignación aleatoria de sujetos a condiciones. No obstante, en ciencia deben cumplirse algunos requisitos para asumir que el tipo de relaciones formalizadas mediante un sistema de ecuaciones impliquen causalidad, lo que deriva en ocasiones en cierta confusión sobre el alcance de la investigación cuando se analizan datos mediante AFC. Sobre esta cuestión, Bollen (1989) realiza algunas aclaraciones sobre la posibilidad de utilizar AFC en el marco de la experimentación que se discuten en el primer apartado 1.1 (para una revisión en mayor profundidad del tema de la causación, consultar los trabajos de Mulaik, 1986, 1993, 2009).

La posibilidad de establecer causalidad a partir de AFC se enfrenta a numerosas limitaciones que precisan de fuentes de evidencia empírica y de elementos de deducción teórica, más bien poco atendidos en la investigación aplicada, tal y como muestra la revisión de la

literatura (apartados 1.2 y 1.3). Abordar la cuestión de la causalidad en este tipo de aplicaciones excede los objetivos del presente trabajo, más si tenemos en cuenta que en Psicología existen numerosas aplicaciones AFC cuyo *background* teórico/empírico es limitado. No obstante, introducir la cuestión de la causalidad es importante para delimitar el objeto de estudio. La revisión de la literatura indica que la causalidad es un tema de debate actual dentro del marco de trabajo SEM, como refleja el intento por revitalizar la distinción clásica entre relaciones causales y estadísticas (West y Kotch, 2014), o la publicación en 2009 de la segunda edición del libro de Pearl *Causality: Models, Reasoning, and Inference*. Esta actualización del concepto de causalidad pone un mayor énfasis en el papel apriorístico de la teoría y del conocimiento sustantivo, la independencia condicional, y la evaluación del ajuste local, y resta importancia a la evaluación de los modelos mediante el uso de índices de ajuste global (apartado 1.4). También cabe señalar la fuerte presencia del “lenguaje causal” en los libros y manuales de referencia sobre SEM/AFC, así como en los artículos que revisan cómo se utiliza esta herramienta en contextos aplicados.

Compartiendo este punto de vista, tratar de establecer relaciones de causalidad debería ser la meta a alcanzar no solamente en la aplicación de un tipo de herramienta que se define como *confirmatoria*, sino también en el avance y en el desarrollo de la Psicología como área de conocimiento. Lo que se quiere resaltar con este capítulo es la importancia de obtener un mayor nivel de evidencias que permitan orientar científicamente la generación y validación de modelos, aportando un tipo de evidencias relacionadas con la consistencia empírica de las variables latentes en un modelo AFC en tanto que hipótesis sustantivas. Como se ha comentado en el prólogo, el objetivo principal del presente trabajo es establecer de forma sistemática la utilidad que tiene la prueba  $\chi^2_{\text{Null}}$ . Para ello, se asume que la especificación del modelo inicial se elabora en base a clústers independientes. El concepto de clúster independiente (McDonald,

1999; McDonald y Ho, 2002) se revisa en los apartados 1.4.1 y 1.4.2, y la definición del modelo de independencia se detalla en el apartado 1.4.3. Además, en este último apartado se justifica la utilización de la estrategia de pre-evaluación propuesta, identificando a sus principales precursores en autores como Jöreskog y Sörbom (1993) y Mulaik (2009).

Por último, queremos señalar que el posicionamiento al elaborar y presentar este trabajo pretende ser neutro respecto a los factores con varianza común limitada o factores VCL, en el sentido de que no se mantiene ninguna posición *a priori* sobre la adecuación de especificar este tipo de factores en los modelos AFC. La pre-evaluación del modelo de independencia en factores VCL puede ser una forma de prevenir la especificación de factores “falsos”, pero también puede ayudar al investigador aplicado a justificar la presencia de factores VCL con relevancia teórica (es decir, siempre y cuando mejoren la representación del constructo).



## 1.1. Modelos causales de medida: conceptos básicos

La investigación en Psicología, y en buena medida en el resto de las Ciencias Sociales, puede ser caracterizada a partir de tres tipos: descriptiva, relacional-predictiva y explicativa (por ejemplo, Shaughnessy, Zechmeister, Zechmeister, y Barroso, 2007; Trochim, 2001). Esta clasificación puede entenderse desde el punto de vista del tipo de relaciones que pueden establecerse en términos de alcance, fiabilidad y validez. Así, la investigación de tipo descriptivo no persigue establecer relaciones entre variables, sino definir, clasificar o categorizar fenómenos de interés. Los investigadores intentan especificar las propiedades, características y perfiles de personas, grupos, comunidades, objetos, etc. (Martínez-Arias, Castellanos y Chacón, 2014).

Por su parte, los estudios relacionales o predictivos tienen como principal objetivo identificar la relación existente entre dos o más variables en un contexto de investigación determinado. Además, el establecimiento de relaciones permite predecir los valores de una determinada variable a partir de los valores del resto de variables implicadas. Por ejemplo, mediante un modelo de regresión múltiple se puede pronosticar la puntuación de un grupo de sujetos en una variable criterio ( $y$ ) a partir de un conjunto de variables predictoras ( $x_1, x_2, x_3, \dots, x_i$ ) relacionadas con dicha variable:

$$y_k = \beta_0 + \beta_1 x_{k1} + \beta_2 x_{k2} + \beta_3 x_{k3} + \dots + \beta_i x_{ki} + \varepsilon_k \quad (1)$$

$$\hat{y}_k = \beta_0 + \beta_1 x_{k1} + \beta_2 x_{k2} + \beta_3 x_{k3} + \dots + \beta_i x_{ki} \quad (2)$$

El subíndice  $k$  se refiere a los sujetos ( $k = 1, 2, 3, \dots, N$ ) y el subíndice  $i$  se refiere a las variables que guardan relación con la variable criterio ( $i = 1, 2, 3, \dots, n$ ). El procedimiento consiste en ajustar primero un modelo de regresión de  $y$  sobre  $x$  (1) y una vez estimada la recta que mejor recoge la relación existente entre el conjunto de variables estudiadas, en una segunda fase se pueden elaborar pronósticos en  $y$  a partir de las puntuaciones de cada sujeto en  $x$  (2).

La investigación cuyo objetivo es explicar, también denominada investigación de tipo causal, trata de ir más allá de las relaciones estadísticas que pueden establecerse entre variables en un intento por dirimir las causas de los fenómenos de estudio. Dentro del ámbito de la investigación cuantitativa, las relaciones entre variables se establecen estadísticamente utilizando algún tipo de prueba inferencial (pruebas sobre correlaciones, covarianzas, coeficientes  $\beta$  de la regresión, diferencias entre grupos, entre otras). No obstante, la mera asociación estadísticamente significativa entre variables es condición necesaria pero no suficiente para formalizar relaciones de tipo causal. En un conocido trabajo clásico, Simon (1954) planteó que para diferenciar una relación (correlación) espuria de una relación genuina en términos causales es necesario introducir información adicional en el marco de un sistema de ecuaciones más amplio:

*“To test whether a correlation between two variables is genuine or spurious, additional variables and equations must be introduced, and sufficient assumptions must be made to identify the parameters of this wider system. If the two original variables are causally related in the wider system, the correlation is “genuine”. ”*

(Simon, 1954, p. 467)

Actualmente, existe un amplio consenso entre investigadores sobre los requisitos que se deben dar en la investigación para poder establecer relaciones causales: 1) existencia de covariación o relación estadística, 2) precedencia temporal y 3) eliminación de explicaciones causales alternativas. Además de la existencia de covariación, las “causas” deben preceder en el tiempo a los “efectos”, ya que si dos sucesos son concurrentes no se puede establecer que uno sea causa del otro. La eliminación de factores explicativos externos es un tema más complejo. Un estudio de carácter explicativo implica la especificación de hipótesis causales, la estimación del modelo causal y la evaluación de la validez del modelo en relación a las hipótesis formuladas. Desde la perspectiva de los SEM (y por extensión, desde la perspectiva de los modelos de medida o AFC), Bollen (1989) describe los tres requisitos que deben cumplir los modelos para asumir causalidad. El simple hecho de denominar a los SEM como *modelos causales* no implica necesariamente el establecimiento de relaciones causales. Para ello estos modelos deben cumplir simultáneamente los requisitos de: 1) asociación, 2) dirección de la causación y 3) aislamiento (o *pseudo*-aislamiento). Estos tres requisitos presentan *a priori* un paralelismo muy fuerte con los tres requisitos para el establecimiento de relaciones causales dentro del enfoque más amplio de investigación expuesto más arriba. La asociación se refiere a la existencia de relación estadística o covariación (1), la direccionalidad se refiere a la precedencia temporal entre una variable “causa” y otra “efecto” (2), y el *pseudo*-aislamiento se refiere a la posibilidad de descartar explicaciones alternativas (3). Dado que el AFC es una herramienta diseñada para contrastar hipótesis sustantivas, la condición de *pseudo*-aislamiento precede a las otras dos ya que el investigador parte de la especificación del modelo a nivel teórico antes de proceder a la recogida de información.

El aislamiento es una abstracción salvo en sistemas de ecuaciones determinísticos, ya que no resulta posible tener la absoluta certeza de que una variable  $x_1$  influye causalmente sobre una

variable  $y_1$  *excluyendo cualquier otra influencia* (la causalidad no es directamente observable). Desde un enfoque probabilístico de la causalidad (Bollen, 1989; Mulaik, 2009) solamente se pueden asumir condiciones de *pseudo*-aislamiento.

$$y_1 = \gamma_{11}x_1 + \varepsilon_1 \quad (3)$$

$$x_1 = \lambda_{11}\xi_1 + \delta_1 \quad (4)$$

En (3)  $\varepsilon_1$  representa la variabilidad en  $y_1$  que se debe a efectos no tenidos en cuenta (el término error en la ecuación de regresión en (1)), y  $\gamma_{11}$  representa la influencia que tiene  $x_1$  sobre  $y_1$ . El supuesto de que  $\varepsilon_1$  no correlaciona con  $x_1$  es la condición de posibilidad que nos permite asumir la influencia de  $x_1$  sobre  $y_1$  en términos de causalidad, al “aislar” dicha influencia de los efectos no tenidos en cuenta ( $\varepsilon_1$ ), es decir, eliminando otras explicaciones alternativas. Pero, por definición, para cada observación el término  $\varepsilon_1$  interfiere en la relación entre  $y_1$  y  $x_1$ , por lo que el aislamiento es una condición imperfecta y solamente se puede asumir la condición de *pseudo*-aislamiento.

La expresión (4) refleja la condición de *pseudo*-aislamiento en la especificación de una variable  $x_1$  en un modelo de medida simple, a partir del cual se estudia la relación entre una variable latente ( $\xi_1$ ) y dicha variable observable. Las variables latentes o factores son variables aleatorias que representan conceptos unidimensionales. Son variables hipotéticas que son asumidas teóricamente a un cierto nivel de abstracción: se asume que operan en la realidad a pesar de no ser directamente observables, por lo que se utilizan para representar formalmente diferentes conceptos (Bollen y Hoyle, 2012; Borsboom, Mellenbergh, y Heerden, 2003). En términos causales, se asume que los factores no tenidos en cuenta (el error representado por  $\delta_1$ )

y la variable latente  $\xi_1$  no están relacionados ( $\text{COV}(\xi_1, \delta_1) = 0$ ), lo que posibilita la condición de *pseudo*-aislamiento (igual que ocurre en (3) entre  $\varepsilon_1$  y  $x_1$ ). El modelo general del AFC puede expresarse como un modelo estructural generalizado a partir de (4) que conecta una o más variables latentes o factores ( $\xi_1, \xi_2, \xi_3, \dots, \xi_j$ ) con, al menos, una variable observable por factor ( $x_{ij}$ ):

$$\Sigma_0 = \Lambda_x \Phi \Lambda_x' + \Theta_\delta \quad (5)$$

$\Sigma_0$  es la matriz simétrica  $i \times i$  que contiene los parámetros del modelo (varianza-covarianzas de las variables observables),  $\Lambda_x$  es la matriz  $i \times j$  de cargas factoriales  $\lambda_{ij}$ ,  $\Phi$  es la matriz simétrica  $j \times j$  de varianzas-covarianzas entre factores ( $\phi$ ), y  $\Theta_\delta$  es la matriz diagonal  $i \times i$  que contiene las varianzas o unicidades de los errores de medida  $\delta$  de cada variable observable. En la práctica, tras la formalización a partir de (5) de un determinado modelo AFC ( $\Sigma_0$ ), se recoge información empírica de las variables observables especificadas en el modelo (**S**), se estima la matriz  $\hat{\Sigma}_0$  derivada, y se analiza el grado de discrepancia o de aproximación entre  $\hat{\Sigma}_0$  y **S**. Se asume la existencia de un modelo “real”, verdadero o poblacional ( $\Sigma$ ).

Un modelo hipotético no logra captar los procesos del “mundo real” si no es capaz de mostrar consistencia empírica. Por tanto, la mayor virtud de los modelos causales es la posibilidad de rechazar modelos que son inconsistentes con los datos. Pero también, y esto supone la mayor debilidad de los modelos causales, el problema es que el modelo real o verdadero es solamente uno de los modelos posibles que pueden ser ajustados a partir de los datos. El ajuste del modelo no es suficiente para establecer consistencia con el “mundo real”. En otras palabras, no es posible asumir  $\Sigma$  a partir de  $\mathbf{S} \approx \hat{\Sigma}_0$ :

*“It is tempting to use model-data consistency as proof of model-reality consistency, but we could be misled by so doing. The problem lies in the asymmetric link between these two consistency checks. “If a model is consistency with reality, then the data should be consistent with the model. But, if the data are consistent with a model, this does not imply that the model corresponds to reality”. ”*

(Bollen, 1989, p. 68)

Cualquier modelo AFC en Psicología es una aproximación a la realidad. Los modelos son representaciones formales de teorías acerca de los fenómenos del mundo real, y su construcción se realiza mediante sucesivas aproximaciones *hipotético-deductivas* a dichos fenómenos. Cada modelo se depura y mejora a través de investigaciones sucesivas, a partir de re-aplicaciones con nuevos datos y nuevas condiciones ( 6 ), asumiendo que este proceso de investigación deriva en un correcto conocimiento de la realidad ( 7 ).

$$\hat{\Sigma}_{0,0} \rightarrow \hat{\Sigma}_{0,1} \rightarrow \hat{\Sigma}_{0,2} \dots \rightarrow \hat{\Sigma}_{0,C} \quad (6)$$

$$\lim_{C \rightarrow \infty} \hat{\Sigma}_{0,C} = \Sigma \quad (7)$$

La letra C se utiliza en las expresiones anteriores para representar el proceso de investigación en torno a un modelo específico  $\hat{\Sigma}_0$ , reflejando la cantidad de investigaciones y de avances que se producen y pueden producirse en un contexto determinado. Idealmente, a medida que aumenta C el modelo propuesto se aproximará con mayor seguridad y concreción a la realidad.  $\hat{\Sigma}_{0,0}$  representa el modelo inicialmente propuesto, el modelo estimado en sus fases iniciales, que ira ganando y consolidando su consistencia empírica durante las fases del proceso

( $C = 1, 2, 3, \dots$ ). Generalmente, es en estas fases de la construcción del modelo teórico en donde se ponen a prueba los requisitos de asociación y de direccionalidad causal de las variables, en donde el modelo suele recibir las re-especificaciones más gruesas por parte del investigador respecto a la selección e identificación de variables latentes y observables. La asunción de *pseudo*-aislamiento es previa al ajuste empírico de  $\hat{\Sigma}_0$ . Esta condición es tentativa en las fases iniciales del proceso, y solamente a medida que aumenta  $C$  se pueden acumular evidencias sobre la influencia causal de las variables latentes sobre las observables.

A un nivel de abstracción mayor, la aproximación de modelos teóricos a la realidad también debe tener en cuenta la existencia de modelos alternativos ( $\hat{\Sigma}_1, \hat{\Sigma}_2, \hat{\Sigma}_3, \dots, \hat{\Sigma}_B$ ) que compiten por reflejar  $\Sigma$  de una manera más plausible. La letra  $B$  representa la cantidad de modelos teóricos que tratan de explicar causalmente determinada “realidad”. Cada uno de ellos trata de obtener el mayor número de evidencias en su propio proceso o diseño de investigación (por ejemplo, para  $\hat{\Sigma}_1$ :  $\hat{\Sigma}_{1,0} \rightarrow \hat{\Sigma}_{1,1} \rightarrow \hat{\Sigma}_{1,2} \dots \rightarrow \hat{\Sigma}_{1,C}$ ). Lo deseable en cualquier campo científico es que  $B < C$ , existiendo el menor número de modelos teóricos compitiendo por explicar un fenómeno determinado y el mayor nivel de desarrollo y de avance posible en la investigación.  $B$  y  $C$  reflejan la asimetría *consistencia empírica-realidad* ya que cuanto mayor es  $C$  más se concreta el modelo teórico que refleja la realidad, al menos idealmente, mientras que cuanto mayor es  $B$  no necesariamente el nivel de desarrollo es mayor. En definitiva, los modelos son aproximaciones *simplificadas* a la realidad, no hipótesis que puedan ser verdaderas (McDonald y Ho, 2002).

Sewall Wright desarrolló la herramienta conceptual *path analysis* con el fin de estimar las magnitudes de los efectos directos cuando el modelo causal verdadero es conocido de antemano (modelos de causas genéticas). No obstante, en Ciencias Sociales rara vez el modelo verdadero es conocido por el investigador. Por esta razón, desde una perspectiva falsacionista

es más razonable asumir que el investigador procede eliminando modelos por falta de consistencia que probándolos o confirmándolos (Bollen, 1989, pp. 71-72). En este sentido, el AFC es más útil para los investigadores como método para *desconfirmar* modelos “falsos” ya que resulta prácticamente imposible confirmar un modelo como “verdadero” o “real” (Kline, 2015, p. 21).

Al menos teóricamente, puede ocurrir que un modelo con ajuste empírico perfecto ( $S = \hat{\Sigma}_0$ ) sea incorrecto o “falso” por falta de consistencia con la realidad, incluso que uno o varios conjuntos de datos ajusten o se aproximen en la misma “cantidad” a diferentes modelos ( $\hat{\Sigma}_{B,C}$ ), en donde solamente uno sea el modelo “verdadero”, tal vez ninguno de ellos. Otro problema añadido, más o menos frecuente, es cuando dos modelos teóricamente distintos (por ejemplo,  $\hat{\Sigma}_0$  y  $\hat{\Sigma}_1$ ) obtienen un grado de aproximación equivalente o casi equivalente. Por lo tanto, la cuestión de la consistencia de  $\hat{\Sigma}_0$  con la realidad no puede ser resuelta analíticamente (estadísticamente), sino que debe ser sometida a consenso por *expert committes* en cada área. Lo que sí puede resolverse analíticamente es la obtención de ciertas evidencias de consistencia empírica, como la asociación entre variables y la dirección de la causalidad (al menos parcialmente), pero también el ajuste del modelo replicado en diferentes muestras, la invarianza de los parámetros, o la relación con variables criterio (consecuencias del modelo). La variedad de evidencias que se pueden analizar cuando se evalúa un modelo AFC es considerable, y su resultado puede y debe guiar a los *expert committes* en el proceso de consensuar y validar teorías.

En el capítulo 13 *How to fool yourself with SEM* del libro de Kline (2010 (3ª ed.), pp. 356-366), se recoge un listado dirigido a los investigadores aplicados que contiene errores y confusiones más o menos frecuentes cuando se usa SEM. Este listado está compuesto por 52 elementos y sus correspondientes recomendaciones, de los cuales se recogen sintéticamente



aquí los más relevantes en relación a la condición de *pseudo*-aislamiento en la evaluación de los modelos, la asociación y la direccionalidad de la causación (entre corchetes se muestra el número correspondiente al listado de Kline).

[1] Especificar el modelo antes de la recogida de información, [14] el principal objetivo de la especificación es poner a prueba la teoría, no el modelo, [41][48][50] no interpretar  $\mathbf{S} \approx \hat{\Sigma}_0$  como una buena aproximación a  $\Sigma$ , [5] considerar cuidadosamente la cuestión de la direccionalidad (variables observables como efecto o como causa: medida reflectiva vs formativa), [7] no especificar correlación entre errores de medida sin una razón substantiva, [9] la sobreidentificación excesiva e injustificada del modelo mejora artificialmente el ajuste de los datos, [10] especificar al menos 3 o 4 variables observables por variable latente o factor, [19] las relaciones entre variables no tienen por qué ser lineales, pueden existir efectos curvilíneos y/o de interacción, [25] la estimación de casos *Heywood* u otros valores ilógicos o aberrantes indica problemas de consistencia en el análisis, [27][43] en caso de re-especificar el modelo, no utilizar criterios exclusivamente estadísticos (buscar/analizar fuentes de evidencia teórica), [31] sopesar el análisis de variables observables altamente relacionadas (por ejemplo,  $r_{x_1x_2} > 0,85$ ): la presencia de colinealidad puede producir inestabilidad en la recuperación de parámetros, [49] dotar de un nombre a los factores es un herramienta de trabajo, no una explicación causal (evitar la cosificación o *reificación* de los factores).

Se recogen a continuación varios elementos del listado de Kline en relación al problema sobre el que versa el presente trabajo, la evaluación de variables latentes con varianza común limitada (factores VCL). El marco de trabajo SEM es muy amplio, coexistiendo multitud de elementos a tener en cuenta que se influyen mutuamente (por ejemplo, la complejidad del modelo, el tamaño muestral y la distribución de los datos analizados). Por esta razón, aprovechamos este listado para ir delimitando los aspectos más importantes relacionados con

la evaluación de factores VCL. Conviene recordar que el enfoque de este trabajo no plantea *a priori* si los factores con VCL deben ser incluidos u omitidos en los modelos AFC, sino que se centra en la obtención de evidencias empíricas que orienten la toma de decisiones.

[4] *Utilizar medidas adecuadas psicométricamente:* el análisis de variables observables que presentan elevado error de medida (falta de fiabilidad) puede producir estimaciones imprecisas. El efecto que tiene el error de medida conlleva generalmente la infraestimación de efectos causales, aunque dependiendo del patrón de correlaciones entre variables, puede llegar a producir una sobreestimación importante.

Si bien estamos de acuerdo con esta recomendación, se quiere señalar que en muchos contextos de investigación aplicada en Psicología la selección de medidas adecuadas no es tarea fácil para el investigador. Con frecuencia, la fiabilidad de las mediciones puede verse comprometida por la dificultad de obtener muestras numerosas, problemas derivados de la selección de la muestra y/o falta de representatividad, obtención de *outcomes* politómicos en lugar de continuos (información recogida mediante ítems), distorsiones importantes en la distribución de respuesta, pérdida aleatoria y/o sistemática de valores, ... Estas limitaciones son importantes y son muy difíciles de superar en la mayoría de los contextos aplicados, por ejemplo, cuando se trabaja con población clínica, o con problemáticas sociales complejas de difícil acceso y/o con escasa incidencia poblacional (suicidio, terrorismo, drogodependencia, violencia exogrupal, etc.)

La utilización de medidas psicométricas fuertes puede ser un estándar de exigencia en investigaciones en las que este tipo de limitaciones estén bien resueltas o compensadas, si bien en otros contextos tal vez sea un ideal difícil de alcanzar. ¿Invalida lo anterior

la posibilidad de utilizar AFC en los contextos de investigación que presentan limitaciones como las comentadas? Tal vez lo más recomendable sea utilizar herramientas de análisis alternativas al AFC, herramientas más descriptivas y/o exploratorias, aunque sin invalidar totalmente la posibilidad de utilizar modelos causales. En todo caso, lo que se quiere resaltar aquí es que el investigador aplicado debe sopesar estas cuestiones, conocedor de las ventajas de las distintas herramientas pero también de sus limitaciones.

Algunas medidas psicométricamente mejorables pueden estar vinculadas causalmente dentro de un sistema más amplio de ecuaciones. Recordemos la diferenciación entre correlación espuria y genuina de Simon: por ejemplo, la estimación de efectos directos relativamente bajos pueden deberse al efecto de variables mediadoras y no tanto a problemas de fiabilidad. Excluir por defecto la utilización de AFC en determinados contextos limita enormemente la posibilidad de estudiar este tipo de consecuencias a nivel causal, aunque el grado de consistencia empírica no sea el ideal desde una perspectiva psicométrica. Por otro lado, las medidas poco fiables son poco recomendables desde el punto de vista de la estimación de los modelos, desde un enfoque puramente analítico, aunque nada nos indica a priori si los procesos causales-probabilísticos del mundo real son más o menos intensos.

[12] *No especificar que un conjunto de variables observables con escasa intercorrelación satura en un mismo factor.* Si no es posible mantener que la medición del factor común es reflectiva, se debe considerar la especificación de una medida de tipo formativo (siempre y cuando exista la suficiente base teórica para ello).

Esta recomendación es una forma de extender la idea de que no necesariamente deben ser omitidos factores VCL en un modelo AFC, ya que cambiando la dirección de la relación causal podrían llegar a obtenerse resultados más consistentes. Si la especificación del factor VCL representa una medición reflectiva, la dirección de la causalidad implica que un cambio en la variable latente provocará cambios en todas las variables observables que lo representan ( $\xi_j \rightarrow x_{ij}$ ). Por su parte, la medición formativa implica que la direccionalidad causal se invierte ( $x_{ij} \rightarrow \xi_j$ ), generando un tipo de efecto o constructo latente que es una combinación lineal y ponderada de todas las variables observables, lo que puede resultar más adecuado en ciertos escenarios. En todo caso, deben tenerse en cuenta dos aspectos en la especificación de modelos de medición formativa. En primer lugar, las variables observables causales son cuestionadas por varios metodólogos por problemas de interpretabilidad e identificación, entre otros problemas (en Brown, 2015, p. 322). En segundo lugar, también es cierto que este tipo de mediciones se han utilizado con menos frecuencia que las reflectivas, por lo que su utilidad como herramienta conceptual puede constituir una vía de desarrollo relevante.

[2] *No omitir causas que están correlacionadas con otras variables presentes en el modelo*: los efectos causales estimados dentro del modelo pueden ser demasiado altos o demasiado bajos si no se tienen en cuenta algunas causas omitidas.

Aspecto relacionado con los anteriores, es precisamente el argumento que se quiere destacar en este trabajo. La evaluación de factores VCL no puede centrarse exclusivamente en omisiones por defecto de variables observables con escasa interrelación, ya que se podría estar restringiendo injustificadamente la validez de

contenido de las mediciones. Actuar de esta manera puede limitar las posibilidades del investigador para comprender mejor el grado de asilamiento con el que pone a prueba sus hipótesis (el grado en el que representa teóricamente los constructos) y, por ende, el modelo teórico evaluado. En términos causales, para mantener o rechazar un factor VCL se debería acumular algún tipo de evidencia empírica que permitiera contrastar su grado de consistencia, en lugar de desestimar su rol dentro del sistema de ecuaciones *antes de ser puesto a prueba* por no cumplir con ciertas exigencias psicométricas. Un análisis previo de los ítems desde un enfoque psicométrico puede mejorar la selección de variables observables en un modelo AFC en términos de estimación de parámetros, si bien esto no dice nada a priori acerca de la causalidad de los procesos del mundo real. Este proceder, muy asentado en la primera Teoría Clásica de los Tests o TCT, puede derivar en una selección incorrecta de variables observables solo por el hecho de obtener una asociación elevada y/o por contribuir a una mejora en el coeficiente alfa de Cronbach, por ejemplo.

En fases iniciales de la investigación, y siempre con el apoyo de evidencias, puede ser más coherente mantener un factor VCL como hipótesis sustantiva dentro de un determinado modelo AFC ( $\hat{\Sigma}_{B,C}$ ). Siguiendo la expresión (6), a medida que aumenta C el factor VCL puede verse reforzado como hipótesis o puede terminar por ser rechazado por falta de validez predictiva, por falta de estabilidad, etc. Salvo en casos muy concretos, es muy posible que esta decisión no pueda tomarse con garantías en una sola investigación observando el tamaño de los efectos directos.

[52] *No interpretar estimaciones relativamente elevadas de efectos directos como evidencia de causalidad*: dado que solamente se pueden establecer condiciones de

*pseudo*-aislamiento, resulta poco plausible realizar inferencias causales a partir de un solo estudio. Aun si las estimaciones de los efectos directos ( $\xi \rightarrow X$ ) resultan en valores elevados, es más razonable asumir que los modelos pueden o no pueden corresponderse con secuencias causales en el mundo real.

Esta recomendación está relacionada con [2]. Incidir nuevamente en la misma idea de que la cantidad de varianza común que pueden acumular las variables latentes en un modelo AFC no es prueba suficiente como para asumir la existencia o la adecuada representación del factor. Este tipo de cuestiones no se pueden resolver con una sola investigación ( $C = 1, 2, 3, \dots$ ). Por supuesto, en condiciones ideales es preferible trabajar con variables latentes que captan una buena cantidad de varianza que con factores VCL. No obstante, su sola presencia no garantiza la condición de *pseudo*-aislamiento, por lo que la necesidad de investigación adicional parece un requisito imprescindible.

[42] *No interpretar un buen ajuste del modelo como una buena predicción de las variables observables*: en modelos correctamente especificados el ajuste no se verá afectado por la presencia de variables latentes que explican una pequeña proporción de la varianza de las variables observables. En otras palabras, las medidas de ajuste o de aproximación indican hasta qué punto el modelo reproduce la matriz **S** con precisión, no hasta qué punto la varianza de las variables observables puede ser explicada.

Este punto anticipa una cuestión importante de este trabajo y es que las medidas que se utilizan habitualmente para evaluar el ajuste de los modelos AFC no parecen ser sensibles a la presencia de factores VCL (ver apartado 1.4.2). Esta falta de sensibilidad

se debe principalmente a dos cuestiones complementarias. La primera es que  $\hat{\Sigma}_0$  y  $\mathbf{S}$  pueden ser aproximadamente iguales incluso en el caso extremo de ausencia de asociación  $\xi_j \rightarrow x_{ij}$ . Si se cumplen ciertos requisitos mínimos de tamaño muestral, número de variables observables por  $\xi_j$ , tipo de distribución de los datos, etc., y en ausencia de otros errores de especificación, la estimación de un parámetro de  $\hat{\Sigma}_0$  que en  $\mathbf{S}$  es *cero-equivalente* puede realizarse con mucha precisión. De esta manera, puede llegar a darse la situación  $\mathbf{S} = \hat{\Sigma}_0$  sin existir relación entre las variables observables ( $\det(\mathbf{S}) \approx \det(\hat{\Sigma}_0) \approx 0$ ).

La segunda cuestión es que la evaluación del ajuste se suele realizar teniendo en cuenta el modelo AFC completo, esto es, teniendo en cuenta el sistema de ecuaciones que integra todas las variables latentes del modelo junto a sus respectivas variables observables y términos error. Este tipo de evaluación puede ser ciega a ciertas partes del modelo (hipótesis sustantivas o factores), si no se producen errores importantes de especificación.

Teniendo en cuenta estas dos cuestiones, parece necesario estudiar otras fuentes de evidencia empírica que permitan poner a prueba factores VCL, más allá de las medidas habituales de ajuste, e incidiendo en la importancia de realizar evaluaciones sobre los factores comprometidos aislándolos del resto de influencias del modelo.

[44] *No confiar excesivamente en las pruebas estadísticas*: especialmente en relación a no interpretar la significación estadística como evidencia del tamaño del efecto o de su importancia sustantiva.

Lógicamente, para poner a prueba factores VCL se requiere no omitir por defecto su especificación en los modelos AFC basándonos en información descriptiva-exploratoria previa (por ejemplo, exclusivamente a partir del análisis de los ítems o de los resultados de AFE previo). Dicha información, si bien es de utilidad para interpretar el resultado de la prueba, no debe servir para tomar una decisión antes de evaluar la presencia del factor en el sistema completo. Además, es necesario diferenciar hasta qué punto el factor VCL es “ruido” o “señal” dentro del modelo. ¿Hasta qué punto la cantidad de varianza explicada tiene algún peso, aunque este sea pequeño? Es aquí donde se puede obtener un primer nivel de evidencias respecto al factor VCL, pudiendo mantenerse como hipótesis sustantiva dentro del modelo o pudiendo ser rechazado. En cualquiera de los dos casos, el investigador debería informar del resultado de esta prueba con el fin de potenciar la *replicabilidad* de los modelos (la omisión por defecto de factores VCL no suele informarse, lo que limita la posibilidad de estudiar su estatus causal en otras investigaciones que evalúan el mismo modelo o cualquier otro modelo en competición).

Si existen evidencias de que el factor VCL es “señal” dentro del modelo, el proceso de confirmación-desconfirmación se irá desarrollando en investigaciones sucesivas ( $C = 1, 2, 3, \dots$ ), en donde su estatus de “señal” será puesto a prueba en cada nueva aplicación. En principio, a medida que aumenta  $C$  el investigador también estará en situación de alcanzar un conocimiento más completo y consistente del conjunto de relaciones causales especificadas en el modelo (factor VCL en relación al resto de variables latentes, y en relación a otras fuentes de evidencia empírica).



Por último, conviene señalar que lo anterior también se relaciona con la capacidad que tiene el AFC para discriminar adecuadamente qué es “ruido” y qué es “señal”. En términos estadísticos, nos estamos refiriendo al estudio del Error Tipo II y de la potencia del AFC para detectar factores VCL. En el presente trabajo se han simulado modelos factoriales con VCL que son “reales” en la población. Por tanto, los resultados obtenidos sirven para evaluar en qué condiciones la aplicación de AFC no muestra sensibilidad suficiente para su detección.

## 1.2. AFC como caso particular de investigación no experimental

En términos generales, es habitual considerar que las principales técnicas de las que dispone el investigador para potenciar la condición de *pseudo*-aislamiento son la manipulación de variables y la aleatorización (asignación aleatoria de sujetos a condiciones y asignación aleatoria de tratamientos a los mismos sujetos). Estas técnicas de control de posibles factores externos, características de la investigación experimental, se aplican previamente a la recogida de datos y a la evaluación del grado de asociación entre variables, e implican hipótesis sobre la dirección de la causalidad (la manipulación de las condiciones estudiadas conlleva la precedencia temporal de una o más VI respecto a una o más VD).

Como se comentó en el apartado anterior, los modelos AFC están diseñados para confirmar-desconfirmar modelos teóricos, por lo que son modelos que permiten al investigador establecer relaciones causales en condiciones de *pseudo*-aislamiento (al menos, plantean la existencia de variables latentes en tanto hipótesis sustantivas). Se trata de herramientas que permiten ir más allá del análisis de la asociación entre variables, de ahí que su objetivo potencial sea explicar procesos del mundo real. La expansión de estas herramientas de análisis ha sido enorme en los últimos 40 años, con importantes desarrollos en la teoría estadística subyacente (Kaplan, 2008). Pero una cosa es el alcance potencial que tiene esta herramienta en la investigación científica y otra distinta el tipo de investigación donde se aplica con más frecuencia. Por esta razón, consideramos que existe cierta ambigüedad al clasificar esta herramienta de análisis como método de investigación no experimental, y tratar dicha ambigüedad resulta de interés para los fines del presente trabajo. En primer lugar, el marco de aplicación de las ecuaciones estructurales puede ser tanto experimental como no experimental, ya que las herramientas de análisis que más se utilizan en la investigación experimental, como

las técnicas de ANOVA o de regresión, pueden entenderse como casos especiales de SEM (Bollen, 1989; MacCallum y Austin, 2000). Conviene recordar que una dificultad importante para realizar experimentos en Ciencias Sociales deriva directamente de fuertes problemas éticos implicados en la manipulación de variables (Harlow, 2005). La ausencia de manipulación de variables es concomitante al diseño de la investigación, por lo que la reflexión sobre la posibilidad de establecer relaciones causales excede al uso de la herramienta utilizada (aunque la incluye lógicamente).

En segundo lugar, la dirección de la causalidad en SEM se hipotetiza en la fase de especificación de los modelos, existiendo diversos procedimientos y técnicas que permiten al investigador minimizar el efecto de factores externos mediante control estadístico. La manipulación de variables y la aleatorización, si bien suponen una importante ventaja frente a la investigación no experimental, no son las únicas formas de potenciar la condición de *pseudo*-aislamiento (*the omitted variable problem*, Bollen, 1989; Mulaik, 2009), por lo que los modelos AFC pueden competir con los experimentos a la hora de descartar hipótesis alternativas en la explicación de procesos del mundo real, incluso en escenarios no experimentales. En este sentido, un aspecto fundamental que se debe evaluar es la invarianza en la medición de constructos mediante AFC, es decir, el grado en el que la medida del constructo se puede generalizar a distintos grupos o submuestras y a distintos momentos temporales, siguiendo la lógica expuesta  $\hat{\Sigma}_{0,C} \rightarrow C = 1, 2, 3, \dots$ . No en vano, la replicabilidad es una de los elementos más importantes de la investigación científica (por no decir *el más relevante*). Algunas técnicas y procedimientos de análisis que permiten poner a prueba la invarianza o estabilidad de los modelos AFC son los estudios con medidas longitudinales, el análisis multi-grupo, estudios de invarianza parcial, y modelos con múltiples indicadores-múltiples causas o MIMIC (Brown,

2015). Sobre algunos problemas que pueden aparecer en los estudios de invarianza factorial puede consultarse a Millsap (2005).

En tercer lugar, en buena parte de la investigación en Psicología en la que se aplica AFC se parte de observaciones que provienen de variables recogidas mediante cuestionarios y tests (ítems o puntuaciones que son combinaciones lineales de varios ítems). En muchos de estos estudios no es posible la manipulación de variables ni la aleatorización sujetos-tratamientos, la condición de *pseudo*-aislamiento se encuentra en fases iniciales (por ejemplo, en cuanto al número de factores) y la direccionalidad causal entre variables no tiene por qué estar totalmente especificada *a priori*. No obstante, estas importantes limitaciones respecto a los experimentos vienen determinadas por el contexto de aplicación y no necesariamente por el tipo de herramienta de análisis utilizada, y esta es a nuestro juicio la principal fuente de ambigüedad. Si en una investigación en la que se utiliza AFC no existe ni manipulación ni aleatorización y el modelo propuesto se evalúa a partir de una sola muestra ( $C = 0$ ), no existen garantías suficientes para establecer las mínimas condiciones de *pseudo*-aislamiento. En esta situación, el objetivo de la investigación no debe ir más allá del estudio de los patrones de interrelación entre variables ni de la elaboración de ciertas predicciones, por mucho potencial que tenga la herramienta empleada.

En relación con la causalidad, el alcance del AFC compite con los experimentos *solo si* los modelos propuestos son replicados en nuevas muestras, con estudios rigurosos de la invarianza de las mediciones, incluso si no es posible manipular variables ni aplicar la asignación aleatoria. El elevado grado de control estadístico así como las posibilidades para potenciar la condición de *pseudo*-aislamiento colocan a esta herramienta *por encima* de otro tipo de técnicas de análisis. Pero es misión de los investigadores elaborar todos estos avances respecto a los modelos inicialmente propuestos ( $C = 1, 2, 3, \dots$ ), igual que en un experimento

es misión de los investigadores estimar el tamaño del efecto y replicar los contrastes con nuevas muestras para generalizar la eficacia de los tratamientos. En otras palabras, por el simple hecho de utilizar AFC no se deriva teoría, igual que por el hecho de utilizar un contraste paramétrico no se deriva automáticamente la generalización de los resultados a toda la población. Tanto la investigación experimental como la no experimental requieren que el investigador aproveche todo su conocimiento para, en la medida de lo posible, considerar y controlar los factores externos que atenten contra la condición de *pseudo*-aislamiento. Por tanto, es necesario examinar tanto las evidencias de carácter experimental como las no experimentales. Las *repeticiones* en cada tipo de investigación aumentarán la confianza en la validez de los patrones de interrelación entre las variables estudiadas (Bollen, 1989).

McDonald (1999) ha descrito el AFC como una “*peligrosa técnica conjetural*” ya que, de ser usada superficialmente, permite generar mediciones *aparentes* en Ciencias Sociales aunque posiblemente incorrectas. El tratamiento superficial de este tipo de herramientas parece ser frecuente en la investigación aplicada (esta cuestión se desarrolla en el apartado 1.3). En relación al tipo de aplicaciones AFC que se suelen realizar, Jöreskog (1993) y Jöreskog y Sörbom (1993) distinguen tres escenarios prototípicos en los que se tratan de ajustar datos muestrales, siempre asumiendo que se trabaja con una sola muestra.

- *Estrictamente confirmatorio* (SC). El investigador formula un determinado modelo y obtiene datos empíricos para ponerlo a prueba. El modelo será aceptado o rechazado en función de esta prueba.
- *Modelos alternativos* (AM). El investigador especifica varios modelos y los pone a prueba en la misma muestra. Se selecciona el modelo que muestra una mayor aproximación entre  $\hat{\Sigma}_0$  y  $\mathbf{S}$ , o se rechazan modelos que obtienen niveles de consistencia poco razonables.

- *Generación de modelos* (MG). El investigador especifica un modelo inicial tentativo-exploratorio. Si no hay consistencia entre el modelo y los datos, el modelo se re-especifica y vuelve a ser puesto a prueba en la misma muestra. Este proceso continúa hasta que el modelo ajusta bien a los datos y cada parámetro del modelo puede ser interpretado a la luz de alguna teoría.

Cuando se utiliza AFC, el escenario SC solamente tiene sentido cuando se ponen a prueba modelos teóricos bien sustentados, con un *background* importante de investigación empírica. No obstante, tal y como señala Jöreskog, es muy infrecuente encontrar que un investigador se conforme solamente con poner a prueba el modelo, sin proponer algún tipo de re-especificación o algún modelo alternativo en caso de rechazo.

Como muestra la literatura (ver apartado 1.3), el escenario AM es relativamente frecuente en las aplicaciones AFC. El investigador pone a prueba distintos modelos alternativos sobre un mismo marco teórico o sustantivo, pero lo que se busca muchas veces es evaluar cuál es la mejor alternativa dentro de un conjunto limitado de posibilidades lógicas o modelos anidados (MacCallum y Austin, 2000): modelo AFC de un factor, dos factores, tres factores, con y sin correlación entre factores, especificación de un factor de segundo orden, ... Más que comparar modelos teóricos distintos, lo que se busca es la solución (no necesariamente sustantiva) que obtenga un mayor grado de ajuste consistencia empírica dentro de un mismo marco teórico. En algunas ocasiones, el marco de trabajo en el que se produce la comparación entre modelos alternativos se deriva de AFE previo, lo que limita fuertemente el análisis desde un enfoque causal. En otras ocasiones, la teoría se deriva del modelo con mejor ajuste, *reificando* así la estrategia confirmatoria.

Todavía a día de hoy buena parte de los escenarios en los que se aplica AFC en Psicología son MG, casi siempre en un contexto de investigación no experimental. Como se comentó en el apartado anterior, es en estas fases de la construcción del modelo teórico en donde se ponen a prueba los requisitos de asociación y de direccionalidad causal de las variables, y en donde el modelo suele recibir las re-especificaciones más gruesas por parte del investigador respecto a la selección e identificación de variables latentes y observables. Muchas veces se evalúan e interpretan modelos que han sido poco replicados en nuevas muestras, con pocas garantías o evidencias acerca de la invarianza de la medición. Se trata de modelos más tentativos y exploratorios que se encuentran en sus fases iniciales de desarrollo. En este tipo de escenarios puede ser de interés utilizar algunas alternativas poco exploradas en la literatura y en la investigación aplicada, como son AFE en el marco del AFC o E/CFA (Jöreskog, 1969; Jöreskog y Sörbom, 1979; Muthén y Muthén, 1998-2012) y los SEM exploratorios o ESEM (Aspharouhov y Muthén, 2009). Ambas herramientas analíticas, descritas en Brown (2015), permiten al investigador *explorar* modelos de medida desde una perspectiva más completa y compleja, desde una perspectiva confirmatoria.

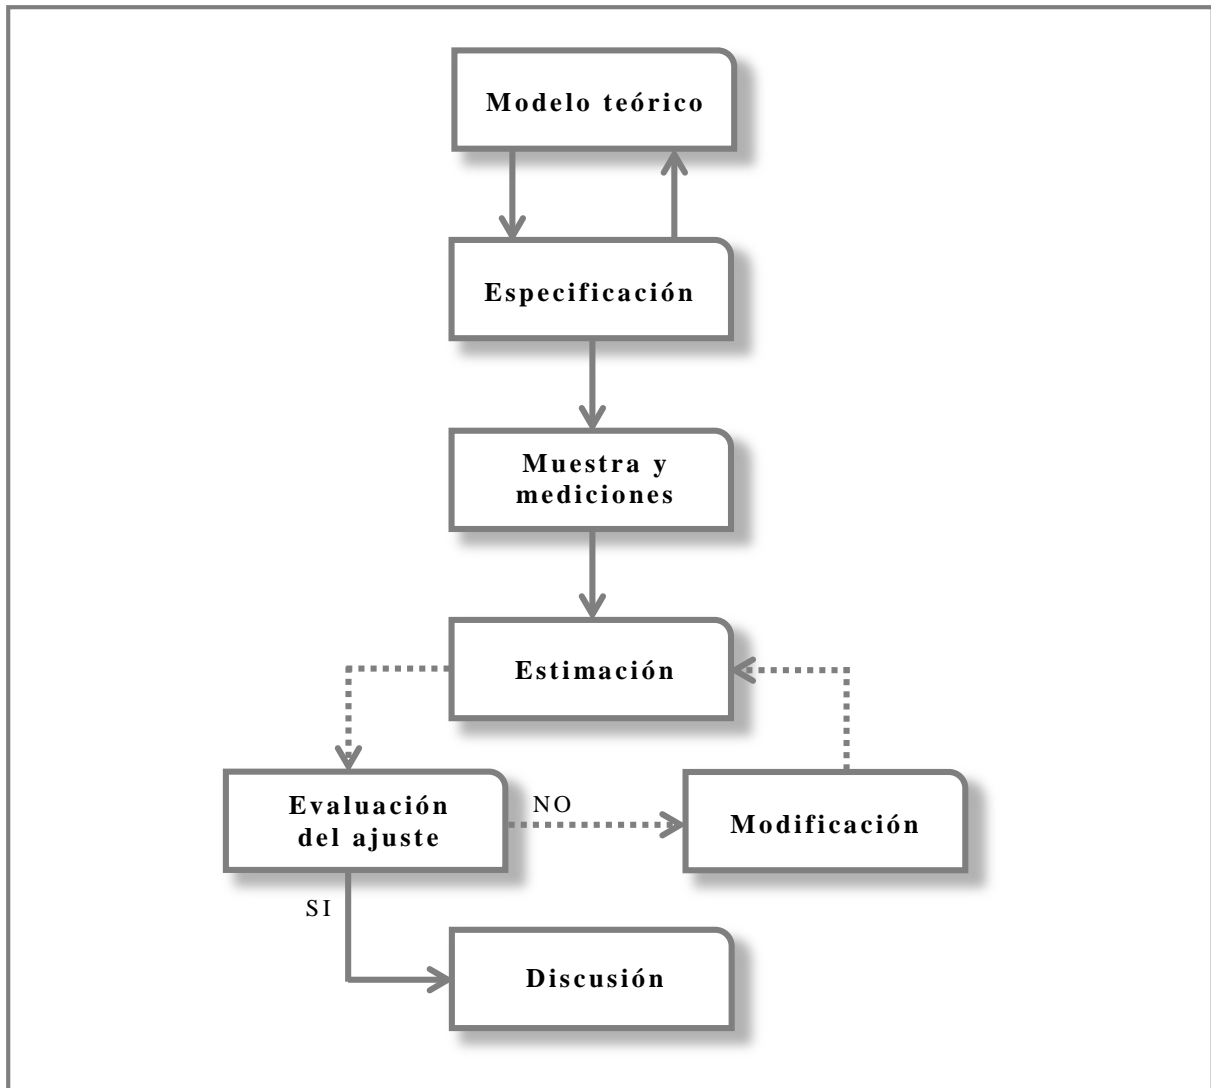
La distinción que aparece en los manuales entre AFC y AFE presenta algunos inconvenientes (Ferrando y Anguiano, 2010). En la distinción AFE-AFC se mezclan dos conceptos, el modelo que se pone a prueba y la finalidad del análisis realizado, por lo que no pueden considerarse dos categorías distintas sino los dos extremos de un continuo. En las fases iniciales de investigación (escenario MG), especialmente en el estudio de fenómenos nuevos, en un análisis puramente exploratorio el investigador analizaría un conjunto de datos sin hipótesis previas acerca de su estructura, dejando en manos de los resultados una tentativa orientación teórica. En el otro extremo, en un AFC el investigador propone una serie de hipótesis bien especificadas en relación al número de variables latentes ( $\xi_j$ ), al patrón de

relaciones entre variables ( $\Lambda_x$ ) y a la relación entre factores ( $\Phi$ ), y las pone a prueba mediante algún conjunto de observaciones (escenarios SC y AM). El problema es que las observaciones del mundo real que se registran mediante ítems y tests no son medidas *factorialmente puras* (sin *cross-loading*, sin correlación entre errores de medida). Este escenario de investigación explica por qué es más fácil obtener una buena aproximación a los modelos cuando se utilizan pocos ítems que cuando se utilizan cuestionarios o tests de tamaño realista, y explica también por qué estructuras factoriales exploratorias que son claras, interpretables y replicables a través de diferentes estudios, muestran ajustes inadmisibles cuando se evalúan mediante AFC (Ferrando y Lorenzo-Seva, 2000; McCrae, Zonderman, Costa, Bond, y Paunonen, 1996). En este escenario, Ferrando y Anguiano (2010, p. 24) proponen utilizar un modelo no restricto (exploratorio) pero con una finalidad confirmatoria, asumiendo que si la investigación está lo bastante avanzada el modelo a utilizar es AFC. Conviene recordar el elevado coste en término de recursos asociado a la aplicación con nuevas muestras, lo que escapa a las posibilidades prácticas de muchos investigadores. Esta es una realidad en la práctica de la investigación aplicada, si bien parece necesario incidir en que las limitaciones se encuentran en el uso e interpretación de la herramienta y no en la herramienta *en sí*.

En el marco de los SEM, Kaplan (2008) sostiene que los problemas sustantivos conducen idealmente a desarrollos metodológicos y estadísticos más avanzados. Con el tiempo, estos nuevos desarrollos deberían promover un mayor conocimiento sobre los problemas sustantivos y un mayor avance en el desarrollo de teorías. No obstante, aunque si bien es posible alcanzar un nivel más preciso en la estimación de asociaciones sustantivas o causales entre variables, los nuevos desarrollos metodológicos deben superar la *práctica convencional* en el uso de este tipo de herramientas. El proceso sobre el que descansa la práctica convencional en SEM, aplicado sobre una misma muestra, se recoge en la Figura 1 (Kaplan, 2008, pp. 9, 216).



Figura 1. Diagrama sobre la práctica convencional en el uso de SEM (Kaplan, 2008)



La aproximación convencional a los SEM se caracteriza de la siguiente forma. Primero, se especifica un modelo estructural ( $\Sigma_0$ ) como representación formal de un determinado modelo teórico ( $\Sigma$ ). Segundo, se selecciona una muestra y se obtienen las mediciones de las variables analizadas. Tercero, se utiliza algún procedimiento de estimación para obtener los parámetros del modelo ( $\hat{\Sigma}_0$ ). Cuarto, se evalúa la consistencia empírica o aproximación entre  $\hat{\Sigma}_0$  y  $S$  mediante pruebas e índices de ajuste. Quinto, en función del resultado de la fase anterior (grado de aproximación) se modifica el modelo mediante algún tipo de re-especificación (por ejemplo,

fijando, liberando y/o equiparando alguno de los parámetros a estimar, eliminando/añadiendo variables observables, o modificando el número de variables latentes). Normalmente, este paso implica una serie de ciclos que consisten en sucesivas modificaciones del modelo hasta que se decide que su consistencia es adecuada, cumpliendo un conjunto de estándares y recomendaciones sobre medidas de ajuste. Sexto, una vez se considera que el modelo está ajustado se discuten los hallazgos en función de la teoría que se quiere evaluar.

Otra cuestión importante relativa al contexto de aplicación no experimental del AFC es que rara vez se utilizan los resultados de un modelo en estudios predictivos, en los que se manipulan variables relevantes relacionadas con la teoría y se analiza su efecto sobre las variables observables. En cierto sentido, el uso convencional del AFC dirige su objetivo directamente *hacia la teoría*, presentando importantes limitaciones en la fase descriptiva y relacional-predictiva de la investigación, de gran importancia en la elaboración secuencial de la investigación científica ( $C = 1, 2, 3, \dots$ ). Esta situación convierte al AFC en un caso singular de investigación (preeminentemente) no experimental. A pesar de su elevado potencial y flexibilidad como herramienta de análisis causal, la práctica habitual omite con demasiada frecuencia la obtención de nuevas evidencias una vez los datos se aproximan a los modelos propuestos a partir de una única muestra, siguiendo el proceso expuesto en la Figura 1. Pero, y como se ha argumentado, los modelos AFC ponen a prueba hipótesis sustantivas, *incluso en investigaciones en las que el sustrato teórico no es demasiado explícito*.

La capacidad del modelo para realizar pronósticos respecto a algún variable criterio relacionada teóricamente es un aspecto crítico en la evaluación de modelos que hipotetizan variables latentes. Si bien es cierto que el concepto de variable latente (constructo, rasgo, etc.) es un elemento fundamental en la investigación en Ciencias Sociales, precisamente por tratarse de hipótesis no observables en el mundo real se debe evitar su reificación (elemento [44] del

listado de Kline; ver también Skrondal y Rabe-Hesketh, 2004). Especificar variables latentes es una potente herramienta de investigación y de análisis, lo que implica considerar las potenciales consecuencias sustantivas de aceptar un determinado modelo AFC mediante criterios relevantes del mundo real (Barret, 2007).

Resulta obvio que las posibilidades que ofrece el marco de trabajo del AFC son enormes. Desde el punto de vista de la evaluación de factores VCL, la búsqueda de evidencias relacionadas con la invarianza de la medición y con el análisis de las consecuencias del modelo en el mundo real exceden los objetivos del presente trabajo. Nuestro interés se ha centrado en un aspecto concreto que debe ser previo (a nuestro juicio) a la evaluación de estas cuestiones. Hay que tener en cuenta que la variable latente en su conjunto es la que tiene estatus de hipótesis sustantiva dentro del modelo, y no necesariamente las variables observables que lo representan. En el presente trabajo se ha tratado de responder a los siguientes interrogantes: ¿Hasta qué punto el AFC tiene sensibilidad suficiente para detectar factores VCL en la población? ¿Qué pruebas y procedimientos dentro del marco del AFC pueden utilizarse para valorar si un determinado factor acumula varianza común suficiente como para mantenerse como hipótesis sustantiva en  $\Sigma_0$ ? ¿Qué condiciones se requieren para poder realizar este tipo de evaluación con un mínimo de garantías? Para responder a estos interrogantes, en el presente trabajo se plantea la evaluación del modelo de independencia ( $\Sigma_{Null}$ ) en estructuras unifactoriales. Dado que cada variable latente especificada en un modelo AFC es una hipótesis sustantiva dentro del modelo multidimensional, se propone evaluar mediante estrategia inferencial (prueba  $\chi^2$ ) si el nivel de varianza común que acumula un factor VCL es suficiente con los datos disponibles. Obtener evidencias de que el factor VCL es “señal” dentro del modelo debe ser requisito previo al análisis de la invarianza de sus parámetros así como al análisis de su capacidad para predecir variables criterio del mundo real.

Dando un paso más en el razonamiento expuesto en el apartado 1.1, si el factor VCL es “ruido” estadístico, entonces el investigador tiene dos opciones: o bien se plantea su eliminación del modelo multidimensional, o bien puede evaluar las condiciones en las que se aplicó AFC en términos de sensibilidad. En el primer caso, estaríamos ante una decisión que hemos denominado como *heurística*, en el sentido de aceptar o rechazar la naturaleza teórica del constructo evaluado, su propia existencia en la población, a partir del análisis directo de los resultados del proceso de estimación (por ejemplo, si se obtiene una matriz  $\Lambda_x$  con cargas bajas). Este tipo de decisiones se suelen tomar a partir de estrategias *data-driven*, más comunes en el marco de trabajo del AFE aunque no exclusivamente. Esta estrategia se utiliza a menudo cuando los investigadores especifican modelos tentativos (escenario MG), independientemente de si se aplica AFE o AFC. El riesgo es que, si los valores estimados de *lambda* no exceden ciertos puntos de corte o recomendaciones, el investigador puede llegar a considerar que el constructo es “falso” en la población. Entonces, la relevancia teórica del constructo en cuestión queda relegada a un segundo plano en “beneficio” del resultado de la estimación.

En el segundo caso, existe la posibilidad de tomar decisiones fundamentadas en la pre-evaluación de factores VCL. Este tipo de decisiones ponen el foco precisamente en la naturaleza hipotética del constructo evaluado, asumiendo que es “verdadero” en la población. Esta preeminencia de la teoría implica el cuestionamiento del AFC como técnica sensible para detectar el constructo evaluado *en determinadas condiciones de aplicación*. Este tipo de no están siendo consideradas en la práctica convencional del AFC, como revela la revisión de las prácticas de publicación. Como dice Barret, “*Whilst the SEM practices of many social scientists may be less than optimal, the use of SEM as a powerful data analysis and causal modelling tool is here to stay.*” (Barret, 2007, p. 820).

De la revisión de la literatura (ver apartado 1.3) se deduce la práctica de eliminar variables observables, incluso de factores, que no reúnen ciertas características psicométricas. Dicha eliminación se produce en la fase de selección de variables, que es previa a la fase de especificación del modelo. No obstante, realizar este tipo de operaciones resta al investigador la posibilidad de *poner a prueba* hipótesis sustantivas que pueden ser relevantes dentro del modelo. De manera complementaria, la presencia de un factor VCL en un modelo AFC multifactorial puede ser “ruido”, o puede permitir *abordar la explicación* de ciertos aspectos de la medición y/o de la teoría que pueden ser complementarios al resto de factores (por ejemplo, efectos del método de medición, presencia de deseabilidad social, efecto Hawthorne, o hipótesis sustantivas de tipo auxiliar/secundario). MacCallum y Austin (2000) inciden en este aspecto: el efecto de selección es algo inherente al proceso de escoger las variables observables que se van a utilizar en un determinado estudio. De hecho, la naturaleza del constructo evaluado puede cambiar en función de las variables observadas seleccionadas, lo que puede influir lógicamente en los resultados e interpretación de un modelo. No existe un efecto único verdadero entre una variable y otra a menos que dichas variables no cambien en el tiempo. Para una mayor comprensión de la naturaleza de este tipo de efectos, el investigador puede realizar evaluaciones en distintos momentos temporales, y esta afirmación es válida tanto para factores VCL como para otros factores que muestren un mejor comportamiento psicométrico.

Cuando los factores presentes en el modelo acumulan una cantidad elevada de varianza, este tipo de evaluaciones no son necesarias, lo que no implica que no sea necesario acumular otro tipo de evidencias, como por ejemplo a partir del análisis de la colinealidad o descartar la presencia de sesgos en la selección de la muestra. Se pueden llegar a obtener matrices definidas no positivas con variables que presentan colinealidad (Wothke, 1993). En este sentido, si el objetivo del investigador es explicar procesos del mundo real, cualquier asociación estimada en

las fases iniciales de generación de modelos requiere acumular evidencias adicionales para poder llegar a ser interpretada como causal. Y los resultados deben informarse para orientar las evaluaciones en nuevas muestras o para la especificación de modelos alternativos ( $\hat{\Sigma}_{B,C}$ ).

En los experimentos, muchos investigadores pueden encontrarse en situaciones similares, aunque la práctica convencional parece estar mejor resuelta, más consensuada. En este tipo de investigación se ponen a prueba hipótesis sustantivas en contextos más controlados gracias a la manipulación de variables y a la asignación aleatoria. En comparación con los escenarios de aplicación del AFC, podría decirse que los escenarios prototípicos de los experimentos son estrictamente confirmatorios (SC). No obstante, elaborar buenos experimentos también es muy costoso, por lo que en muchas ocasiones existen importantes limitaciones relacionadas con la condición de *pseudo*-aislamiento, debidas a otro tipo de factores no controlados como el tamaño y selección de la muestra (muchas veces seleccionada entre estudiantes universitarios), la selección de niveles de las variables manipuladas, restricciones de rango en los *outcomes* observados, etc. Además, el contraste de hipótesis estadístico que se realiza en las pruebas inferenciales tradicionales no está exento de malinterpretaciones, similares a las comentadas sobre reificación de los factores o sobre la asimetría existente entre consistencia empírica y consistencia con el mundo real.

El contraste de una hipótesis estadística pone a prueba la consistencia empírica de un determinado enunciado (una distribución, una diferencia, una relación, etc.), no pone a prueba hipótesis científicas. Contrastar hipótesis estadísticas implica poner a prueba la compatibilidad de los datos con nuestras hipótesis sustantivas. Las conclusiones que pueden extraerse sobre las hipótesis científicas derivadas de las hipótesis estadísticas dependen del grado de conexión entre ambas, y esta conexión puede llegar a ser compleja. En los experimentos la práctica convencional exige estimar el tamaño del efecto cuando el resultado del contraste supone

rechazar la hipótesis nula, por ejemplo mediante el índice  $\hat{\omega}^2$  en los modelos ANOVA o mediante  $R^2$  en los modelos de regresión. El objetivo que persiguen estas medidas es cuantificar la intensidad de la relación estadísticamente significativa, ya que los contrastes pueden verse fuertemente afectados por el tamaño de la muestra y por la distribución de los datos, principalmente. En esta práctica convencional del análisis de datos se explicita claramente que un resultado estadísticamente significativo no tiene por qué ser sustantivo, unificando así la presentación de resultados para la comparación entre experimentos o modelos. Por otro lado, los resultados con un tamaño del efecto limitado no se descartan automáticamente, sino que se comparan con otros resultados, con la investigación previa (por ejemplo, mediante meta-análisis). Y los resultados con tamaño del efecto limitado son abundantes en la investigación aplicada en Ciencias Sociales.

Parece claro, por tanto, que para poder interpretar relaciones estadísticas de forma sustantiva primero hay que probar que existe asociación estadística y *cuantificar su magnitud*, pero en AFC no se realiza el contraste previo sobre las variables latentes. Tal vez el contraste no sea necesario en aquellas variables latentes que acumulan una importante proporción de la varianza común (si bien deberían considerarse otros aspectos), pero sí parece necesario obtener evidencias en el caso de factores VCL. ¿Por qué las variables latentes no tienen el mismo estatus en la práctica convencional del AFC que en la de los experimentos? De hecho, el nivel de evidencias que se deberían obtener cuando se trabaja con variables latentes debería ser más estricto, precisamente por su naturaleza no observable. Una vez superada la prueba de significación estadística, que en el presente trabajo se sustenta en  $\chi^2_{\text{Null}}$ , el investigador no solo está en disposición de estudiar la naturaleza causal del factor VCL ( $\hat{\Sigma}_{B,C}$ ), sino también de cuantificar su magnitud en términos de medición: análisis de fiabilidad y  $R^2$ . Una ventaja

adicional de este enfoque es que supone una aproximación más unificada respecto a la evaluación de los modelos estadísticos inferenciales.



### 1.3. Recomendaciones sobre AFC en contextos aplicados.

La utilidad del Análisis Factorial (AF) para el desarrollo de teorías depende directamente del tipo de decisiones que toma el investigador en el diseño de los estudios y en la forma en la que esta técnica se implementa en la práctica. En este apartado se expone de forma sintética las prácticas más frecuentes en la publicación de modelos AF, identificadas a partir del trabajo de varios autores que han revisado las publicaciones que utilizan AF/SEM en varias revistas relevantes. La mayor parte de estos trabajos de revisión señalan importantes limitaciones y carencias. A continuación, y enlazando con la práctica convencional de las publicaciones AF-SEM, en este apartado se detallan las recomendaciones más frecuentes que se describen en los artículos de referencia. Se da la circunstancia de que en muchos casos los artículos citados incluyen tanto la revisión de la práctica convencional como una serie de recomendaciones dirigidas a mejorar dicha práctica. La mayoría de las recomendaciones pueden aplicarse tanto al marco del AFE como al del AFC/SEM (Brown, 2015).

Fabrigar, Wegener, MacCallum, y Strahan, (1999) destacan la necesidad de realizar revisiones sistemáticas de las publicaciones sobre aplicaciones de AFE para una revisión crítica de esta herramienta. En un estudio ya clásico que realizaron sobre el uso del AFE en la investigación psicológica, estos autores revisaron sistemáticamente todos los artículos publicados entre 1991 y 1995 en *Journal of Personality and Social Psychology* (JPSP) y en *Journal of Applied Psychology* (JAP). Se seleccionaron ambas revistas por su prestigio y por pertenecer a ámbitos de investigación en los que se utiliza de forma extensa el AFE. Se resumen a continuación los resultados más relevantes desde el punto de vista de los objetivos del presente trabajo:

- El AFE es una herramienta que se aplica con frecuencia en la investigación psicológica (159 artículo de 883 en JPSP y 58 de 455 artículos en JAP, 16,2% en total), en una gran variedad de temas o áreas de investigación (60 en JPSP y 30 en JAP).
- Entre todos los artículos revisados, el ratio de variables observables por factor más frecuente es de más de 6 (42,4%), seguido del ratio 3:1 (17%), del ratio 4:1 (16,6%), y de los ratios 5:1 y 6:1 (19,8% conjuntamente).
- En general, la fiabilidad promedio de las mediciones se puede considerar psicométricamente como adecuada, con valores de 0,70 o superiores en el 50,2% de los artículos analizados. Sin embargo, en un 42,4% de los artículos no se suministró dicha información.
- Especialmente relevante es el hecho de que en ninguno de los artículos analizados se suministraron las *comunalidades* o cargas factoriales ( $\hat{\lambda}_{ij}$ ), mucho más informativas sobre la solidez de los resultados AFE que la fiabilidad de la medición. Solamente en 18 artículos se suministraron las matrices de correlaciones, lo que permitió a los autores del estudio calcular los valores de  $\hat{\lambda}_{ij}$ , encontrando valores entre 0,12 y 0,65 (mediana = 0,425).
- En el 44,2% de los artículos analizados el tamaño muestral sobre el que se aplicó AFE se componía de 200 observaciones o menos (en el 17,5% de los casos se componía de 100 observaciones o menos). En un 22,6% de los artículos se utilizaron muestras con 200-400 observaciones y en un 33,2% se utilizaron muestras con 400 observaciones o más.
- En un 40,5% de las publicaciones no se explicitaban las decisiones adoptadas sobre el número de factores de los modelos propuestos, frente al 59,5% restante en el que se había seguido algún tipo de criterio más o menos consensuado (regla Kaiser > 1, gráfico

de sedimentación, y varios métodos conjuntamente). Solamente en 6 de las 217 publicaciones analizadas se siguieron criterios sustantivos o de carácter teórico.

Izquierdo, Olea, y Abad, (2014) realizaron una revisión más actual de la aplicación del AFE en el contexto español de publicación (117 estudios AFE publicados entre 2011 y 2012), encontrando nuevamente importantes tasas de decisiones injustificadas o erróneas respecto al uso de esta técnica de análisis. En general, estos autores observaron que algunos aspectos de la aplicación AFE habían mejorado respecto a revisiones anteriores (tamaño muestral y ratios variables observables/factor más elevados, inclusión de análisis preliminares respecto a la fiabilidad y a la adecuación muestral de las mediciones). Por el contrario, casi en un 40% de las aplicaciones revisadas se utilizaba AFC tras aplicar AFE en la misma muestra. Además, en varios estudios se seguía utilizando la regla  $K > 1$  como criterio de extracción de factores, o se eliminaban variables observables sin replicar nuevamente el modelo para re-evaluar la estructura factorial. Otras deficiencias identificadas se relacionaban con la falta de información sobre las variables observables que representan a cada factor, sobre la matriz de cargas factoriales y sobre la matriz de correlaciones entre factores.

En el contexto de las publicaciones que utilizan SEM, MacCallum y Austin (2000) revisaron 500 artículos en un total de 16 revistas de Psicología entre los años 1993 y 1997. Entre los artículos revisados se incluían tanto a aquellos que presentaban modelos AFC, como modelos *path* (los que describen las relaciones de dependencia entre variable latentes) y modelos SEM completos o estructurales (la combinación de los otros dos). Entre los tipos de SEM analizados, estos autores distinguieron estudios de tipo transversal (más comunes en psicología social, de la personalidad, de las organizaciones e industrial), y estudios longitudinales (más comunes en psicología evolutiva o del desarrollo). Aunque existen

aplicaciones de calidad entre los artículos revisados, se identifican varios aspectos problemáticos. En primer lugar, los resultados del estudio indicaron que los investigadores suelen generalizar excesivamente los resultados y hallazgos tras aplicar SEM. No obstante, las conclusiones de una aplicación SEM deben limitarse a la muestra particular analizada, a las variables utilizadas y al momento temporal al que hacen referencia. Relacionado con lo anterior, los investigadores no suelen definir la población objeto de estudio, la población de interés, por lo que la generalización del modelo puesto a prueba se encuentra limitada también en este punto.

En segundo lugar, los investigadores suelen ser más favorables al modelo que se evalúa (sesgo confirmatorio), lo que se refleja en cierta sobrevaloración positiva de las medidas de ajuste y en cierta renuncia a considerar explicaciones alternativas de los datos. La presencia de este sesgo es especialmente importante en el marco de trabajo SEM, ya que lo razonable es asumir la existencia de modelos alternativos consistentes empíricamente. Sobre las estrategias de análisis propuestas por Jöreskog (escenario SC, AM y MG), es interesante el siguiente resultado: el 20% de los artículos se aplicaron en el escenario estrictamente confirmatorio (SC), el 25% en el escenario de generación de modelos (MG) y el 55% restante en el escenario de comparación entre modelos alternativos (AM). Estos resultados contradicen en parte la presencia que Jöreskog (1993, Jöreskog y Sörbom, 1993) concede a estos escenarios en la investigación aplicada, aunque es posible que esto se deba a que los resultados de la revisión se ceñían exclusivamente a las publicaciones en campos de investigación aplicada en Psicología. No obstante, lo que parece evidente es que las limitaciones que se desprenden de la revisión en este tipo de literatura indican que el escenario de aplicación SEM se mueve entre lo exploratorio y lo confirmatorio, con importantes carencias a nivel de justificación teórico-causal.

En tercer lugar, MacCallum y Austin (2000) identificaron otros aspectos considerados como problemáticos: aspectos relacionados con los datos, con el proceso de estimación y con la interpretación de los modelos. En torno a un 18% de los artículos analizados utilizaban muestras compuestas por menos de 100 observaciones, aproximadamente el 50% de los artículos analizados aplicaron SEM sobre la matriz de correlaciones, y en casi la mitad de los artículos no se reportó la unicidad de las variables observables o endógenas.

McDonald y Ho (2002) revisaron artículos con aplicaciones SEM publicados entre 1995 y 1997. Esta revisión se realizó a partir de las publicaciones de un buen número de revistas de investigación aplicada en Psicología y en Educación, seleccionando finalmente 41 artículos que cumplían con los siguientes requisitos: en el artículo se proporcionaba el *path diagram* del modelo, los modelos ajustados incluían tanto la parte de medición como la estructural (se excluyeron modelos puramente factoriales o modelos estructurales sin variables latentes), y se analizaron solamente modelos ajustados a partir de una sola muestra (se descartaron análisis multigrupo). Entre los resultados principales que se derivan de este trabajo destacan limitaciones en la información relacionada con la identificabilidad de los modelos de medida y los modelos *path*, con el cumplimiento de supuestos estadísticos, con la presencia y tratamiento de valores perdidos, el tipo de matriz utilizada, los parámetros estimados y los errores de estimación.

Jackson, Gillaspy, y Purc-Stephenson, (2009) indican que desde la década de los 90 se ha producido en la investigación psicológica una tendencia positiva en el uso de AFC, especialmente en el desarrollo de escalas y en la evaluación de la validez de constructo. Estos autores realizaron un estudio sistemático entre todas las revistas publicadas por la *American Psychological Association* (APA) entre 1998 y 2006, como continuación temporal del estudio realizado por McDonald y Ho (2002), centrando su atención en los AFC o modelos de medida.

Respecto a estudios anteriores, una novedad importante introducida por el trabajo de Jackson et al. (2009) es que analizaron las prácticas de publicación en todos los modelos evaluados en cada estudio, que suelen ser más de uno. Los artículos fueron seleccionados a través de la base de datos *PsychINFO*, y se analizaron un total de 194 estudios (1.409 modelos AFC), y el diagnóstico realizado es bastante más detallado en cifras que las revisiones de MacCallum y Austin (2000) y de McDonald y Ho (2002). Los resultados más relevantes para el presente trabajo son los siguientes:

- El 75,5% de los estudios analizados versaban sobre validación/evaluación de la estructura factorial de algún instrumento (el 77,7% de los cuales evaluaba instrumentos desarrollados previamente y el 22,3% restante evaluaba nuevos instrumentos). El 15,8% de los estudios analizados evaluaba constructos o teorías y el 8,8% evaluaba el modelo de medida como paso previo al ajuste de un modelo SEM.
- A diferencia de los resultados reportados por MacCallum y Austin (2000), en esta revisión se descartó la posibilidad de identificar los escenarios propuestos por Jöreskog (SC, AM y MG) por falta de información.
- El 63,8% de los estudios planteaba de partida más de un modelo. Entre los 1.409 modelos analizados, el 50,5% correspondían a modelos con factores correlacionados, el 12% a modelos con factores ortogonales, el 10,6% a modelos jerárquicos, análisis multigrupo (9,8%), un solo factor (9,5%), y estudios multirasgo-multimétodo o MTMM (2,3%). En un 5,3% de los modelos no resultó posible identificar sus características.
- Entre los modelos finalmente elegidos por los investigadores, la mediana del tamaño muestral fue 389, con un rango que oscilaba entre 58 y 46.133 observaciones. En un 20,3% de dichos modelos se utilizaron muestras con menos de 200 observaciones, y en un 14,7% se utilizaron muestras con más de 1.000 observaciones.

- En cuanto al tamaño de los modelos, un 25% trabajaba con 12 variables observables o menos, un 25% con 13-17 variables, y la mitad restante con 18 o más variables.
- Un 89,6% de los modelos especificaba 6 variables latentes o menos (mediana = 3 factores).
- En general, los estudios analizados no ofrecen demasiada información sobre la preparación de los datos en términos de supuestos matemáticos, valores perdidos, ni si se realizó o no algún tipo de transformación de los datos.
- En el 34,5% de los casos se informó de la utilización de la matriz de varianzas-covarianzas, en un 4,1% se informó de la utilización de la matriz de policóricas, y en un 1,5% se informó de la utilización de la matriz de correlaciones. En el 59,8% restante no se suministró esta información.

También se han realizado algunos trabajos que han revisado la aplicación de SEM poniendo el foco en contextos de investigación más específicos, como el realizado por Shah y Goldstein (2006) en el área directiva de operaciones (*operations management*). Ante el fuerte incremento de aplicaciones SEM en este contexto de investigación, estos autores revisaron 93 artículos (143 modelos) publicados entre 1984 y 2003 en cuatro de las principales revistas del área, todas ellos de carácter transversal (un 15,4% con validación cruzada en nuevas muestras y un 18,9% utilizando la mitad de la muestra para la validación). Al igual que en alguna de las revisiones descritas más arriba, se revisaron aplicaciones de AFC (26,6%), modelos *path* (18,2%) y modelos estructurales (52,4%). En 4 de los modelos analizados no fue posible identificar su tipología. Los resultados obtenidos en este estudio son bastante ilustrativos, y van en la misma dirección que las revisiones realizadas con carácter general y/o en otras áreas, lo que refleja a nuestro juicio que la práctica convencional en la aplicación de SEM está bastante

extendida. En términos generales, y al igual que ocurría en la revisión de Jackson et al. (2009), los artículos no reportan información suficiente sobre la preparación de los datos (distribución de los datos, valores perdidos, etc.). Además, tal y como observaron MacCallum y Austin (2000), con frecuencia los resultados de estos artículos eran generalizados excesivamente, sin aportar información relativa a la población objeto de estudio y con presencia de sesgos confirmatorios.

Ninguno de los artículos analizados presentó alguna estimación de la potencia estadística ( $1 - \beta$ ). Shah y Goldstein (2006) estimaron este valor en el 71,3% de los modelos a partir de la información suministrada en los artículos correspondientes, de los cuales solo el 37% presentó valores adecuados de potencia ( $\geq 0,8$ ). Por otro lado, en el 30,8% de los casos se informó de la utilización de la matriz de varianzas-covarianzas, en el 25,2% se informó de la utilización de la matriz de correlaciones y en el 44,1% restante no se informó del tipo de matriz utilizada para estimar los modelos. Solamente en el 34,4% de los artículos revisados se suministró la matriz analizada, lo que resulta imprescindible para replicar los resultados. Sobre los métodos de estimación, llama la atención que en el 48% de las aplicaciones no se suministró ninguna información (sobre el resto de aplicaciones, el 68,9% informó de la utilización de ML). En el 96,5% de los modelos se informó de los coeficientes estimados, en el 62,9% se informó del valor del estadístico  $t$ , en el 14,7% de los errores estándar y en un 2,1% de los intervalos de confianza. Centrándonos en los resultados relativos al AFC:

- El tamaño medio de las muestras utilizadas fue de 245 observaciones (mediana = 141). La muestra más pequeña tenía 63 observaciones y la más grande 902.
- El número medio de parámetros que fueron estimados fue de 38 (mediana = 31), oscilando en un rango entre 8 y 98 parámetros. El número medio de variables observables fue de 13,5 (mediana = 12,5, rango entre 4 y 32).



- Los modelos analizados especificaban entre 1 y 10 variables latentes, con una media de 3,7 y una mediana de 3. La media de variables observables por variable latente fue de 5,2 (mediana = 4). El 24% de los modelos analizados presentaba un ratio inferior a 3:1 variables observables por factor.
- El 28,9% de los modelos finales evaluados especificaban correlación entre errores de medida, aunque en ningún caso se justificó teóricamente dicha especificación. No se especificaron *cross-loading* (o *double-loading*) en ninguno de los modelos AFC revisados.
- Algunos aspectos de interés que no fueron tratados específicamente en las revisiones anteriores tienen que ver con la evaluación del modelo de medida: fiabilidad, validez convergente y discriminante. Sin distinguir entre AFC, modelos *path* y SEM, en el 86% de las aplicaciones se informó de alguna de las siguientes medidas de fiabilidad: para cada ítem, fiabilidad total o varianza media explicada. En un 65,7% de las aplicaciones se realizaron evaluaciones de la unidimensionalidad de cada variable latente si bien, con frecuencia, el coeficiente alfa de Cronbach se utilizaba incorrectamente como medida de unidimensional. En un 69,2% se realizaron evaluaciones de validez discriminante y convergente y en un 53,1% se informó de la cantidad de varianza explicada por los modelos ( $R^2$ ).

La revisión de la literatura indica que, si bien algunos aspectos técnicos de las aplicaciones están mejorando con el tiempo, la aplicación AF-SEM muestra importantes limitaciones. El período de tiempo sobre el que se pueden generalizar estos resultados es amplio, desde la década de los 90 hasta principios de la década de 2010 para AFE, y desde principios de los 90 hasta mediados de la década del 2000 para AFC-SEM. Sorprende observar

que, a pesar de que desde hace tiempo existen numerosas recomendaciones sobre cómo aplicar este tipo de herramientas (y recomendaciones sobre cómo informar de su aplicación), los problemas y limitaciones que se identifican en estas revisiones son bastante estables en el tiempo y se manifiestan de forma similar en distintas áreas de conocimiento. La revisión de la literatura refleja que no parece haberse entendido la importancia de seguir este tipo de recomendaciones, ni las implicaciones prácticas que tiene trabajar con una técnica confirmatoria. Aunque la revisión de la literatura cubre de forma desigual todo el intervalo temporal de las publicaciones hasta la actualidad, la estabilidad con la que se observan e identifican limitaciones nos hace pensar que persisten todavía a día de hoy. En todo caso, actualizar la revisión de las aplicaciones AFC excede los objetivos y el alcance del presente trabajo, por lo que asumimos que las problemáticas identificadas siguen plenamente vigentes en un buen número de contextos de aplicación.

A continuación, se recogen las principales recomendaciones sobre la aplicación AF-SEM que tratan de orientar y de corregir las distintas limitaciones identificadas respecto al análisis causal y respecto a las condiciones de aplicación. Señalar que los aspectos relacionados con el ajuste de los modelos no son recogidas aquí (igual que no han sido sintetizados en la revisión anterior). Sobre estos elementos de la aplicación AFC se reflexiona en el apartado 1.4.2 y en el Capítulo 3 de resultados. Otros aspectos relevantes como el tipo de distribución de los datos (datos continuos vs. discretos, asimetría, etc.) se retoman también en el Capítulo 2 al describir los principales métodos de estimación de parámetros.

### *AFE vs. AFC*

La mayor parte de los estudios factoriales en Psicología evalúan la estructura de un test a partir de sus ítems o evalúan hipótesis de tipo dimensional utilizando como medidas puntuaciones en diferentes tests. En situaciones en las que el investigador no dispone de un sustrato teórico y/o una base empírica previa fuerte, AFE es el tipo de aplicación más recomendable, ya que el número de soluciones posibles puede ser demasiado elevado en términos prácticos como para ser evaluadas mediante AFC (Fabrigar et al., 1999; Ferrando y Anguiano, 2010; Ferrando y Lorenzo-Seva, 2000). No obstante, un aspecto a tener en cuenta es que el término *exploratorio* no es sinónimo de ausencia de teoría, de ausencia de hipótesis acerca del número de factores que definen el dominio evaluado y su relación (Izquierdo et al., 2014). Combinar la aplicación AFE y AFC también se ha propuesto como estrategia de análisis en este tipo de situaciones, siempre y cuando no se apliquen sobre la misma muestra (por ejemplo, si la muestra es lo suficientemente grande, aplicar AFE sobre la mitad de la muestra y tratar de confirmar la solución con AFC sobre la otra mitad; Brown, 2015). Como se comentó en el apartado anterior, algunos autores proponen estrategias E/CFA o ESEM para *explorar* modelos de medida desde una perspectiva confirmatoria.

### *Selección de la muestra*

Actualmente, existe bastante acuerdo en considerar que el tamaño de la muestra ( $N$ ) a utilizar cuando se aplica AF depende de la complejidad del modelo evaluado, existiendo diferentes aspectos a tener en cuenta de manera conjunta como el número de variables latentes y observables, la distribución de los datos y el nivel de comunalidad. Cuando cada factor está sobreidentificado (al menos 3 o 4 variables observables y una comunalidad promedio  $\geq 0,7$ ) la

recuperación de parámetros puede ser muy estable a partir de muestras muy pequeñas ( $N = 100$ , incluso menos), mientras que en condiciones menos favorables se debería trabajar con, al menos, 200 observaciones. En malas condiciones puede que incluso muestras  $N = 500$  no sean suficientes (Fabrigar et al., 1999; MacCallum, Widaman, Zhang, y Hong, 1999). Otros autores como Mundfrom, Shaw, y Ke (2005), indican que utilizar al menos 7 variables observables por factor ( $n$ ) reduce el efecto del nivel de comunalidad. Mediante simulación, con un ratio de variables observables por factor  $\geq 7:1$  y un nivel de comunalidad bajo (entre 0,2 y 0,4), se obtuvieron niveles altos de estabilidad en la recuperación de parámetros con muestras entre 100 y 180 observaciones.

Una recomendación extendida sobre  $N$  se refiere a la estimación del tamaño muestral mínimo necesario para obtener determinados niveles de potencia estadística (Brown, 2015; Fabrigar et al., 1999; MacCallum, Browne, y Sugawara, 1996; Muthén y Muthén, 2002; Satorra y Saris, 1985). Actualmente, se recomienda utilizar tamaños muestrales asociados a niveles de potencia  $(1 - \beta) \geq 0,8$ , y su estimación debe ser previa a la fase de recopilación de datos (en el apartado 3.3 se retoma el análisis de la potencia). No obstante, hay que tener en cuenta que los valores muestrales mínimos que se obtienen mediante estos procedimientos no necesariamente permiten obtener estimaciones precisas de los parámetros (MacCallum et al., 1996). Un número elevado de variables observables por factor tiene la ventaja de compensar tamaños muestrales reducidos (Marsh, Balla, y McDonald, 1988), aunque tiene una desventaja importante: se necesita un tamaño de muestra mayor para obtener valores adecuados de  $1 - \beta$  (Shah y Goldstein, 2006). Aumentar  $n$  implica también una desventaja desde la perspectiva de representar parsimoniosamente el constructo evaluado.

Por otro lado, la selección por conveniencia de muestras (muestreo no probabilístico) no tiene por qué presentar problemas cuando el constructo a evaluar se puede inferir a partir de la

población general. Para McDonald y Ho (2002), en algunas aplicaciones en las que el objetivo principal es el desarrollo de tests, la selección de muestras por conveniencia no es un aspecto crítico, al menos en una primera fase. No obstante, los investigadores deben sopesar el grado de homogeneidad de la muestra (por ejemplo, selección de la muestra entre estudiantes universitarios) ya que se pueden obtener mediciones con rango restringido, lo que deriva en correlaciones atenuadas entre las variables observables (Fabrigar et al., 1999; Ferrando y Anguiano, 2010). En línea con lo anterior, parece relevante que en las aplicaciones AF los investigadores informen no solo de la representatividad de las muestras, sino también de su procedencia e idoneidad. Los investigadores deben definir explícitamente la población de interés incluso en el caso de que no sea factible su estudio directo en la práctica (Jackson et al., 2009; MacCallum y Austin, 2000; Shah y Goldstein, 2006). Obtener muestras representativas (mediante muestreo probabilístico) es una opción a tener en cuenta para superar este tipo de limitaciones, aunque costosa.

Otro aspecto relacionado con lo anterior es la presencia y tratamiento de valores perdidos en la investigación aplicada (Jackson et al., 2009; McDonald y Ho, 2002). Tanto el efecto de obtener muestras no probabilísticas como el de aplicar ciertas estrategias para tratar valores perdidos (eliminación *listwise*, sustitución por media o mediana, etc.), pueden producir cambios no controlados en las varianzas y covarianzas de las variables latentes. Una alternativa más fiable para el tratamiento de valores perdidos es la asignación de valores plausibles mediante imputación múltiple.

*Selección de variables observables*

Un aspecto especialmente relevante tanto en AFE como en AFC (y de especial relevancia para este trabajo), es que la naturaleza del constructo puede cambiar en función del tipo de variables observables seleccionadas, ya que probablemente dicha selección influirá en los resultados de la aplicación y en su interpretación (MacCallum y Austin, 2000). Seleccionar variables observables “irrelevantes” para medir/evaluar el dominio de interés puede derivar en la aparición de factores espurios, o en la omisión de factores relevantes. En este sentido, el investigador debe definir cuidadosamente el dominio de interés (operativización de las variables latentes) y concretar de manera consecuente cuál va a ser el proceso de selección de medidas (Krueger, Emons, y Sijtsma, 2013; Little, Linderberger, y Nesselroader, 1999; Shah y Goldstein, 2006).

Una vez definido el dominio o constructo a evaluar, una recomendación habitual es la de utilizar entre 3 y 5 variables observables por factor, atendiendo a las características psicométricas de las mediciones (fiabilidad y comunalidad de las variables observables: MacCallum et al., 1999; Velicer y Fava, 1998), potenciando así la identificabilidad de los modelos y en consonancia con el concepto de validez de contenido. Este tipo de recomendaciones están también relacionadas con el tamaño muestral a utilizar, como se ha comentado. En aplicaciones que evalúan la estructura interna de tests mediante AFE, Izquierdo et al. (2014) sugieren a los investigadores que realicen análisis preliminares de la calidad métrica de las variables observables con el fin de seleccionar las más adecuadas, reportando en las publicaciones la media, desviación típica y la correlación ítem-test, así como el valor de alfa de Cronbach de la escala. Sobre esta cuestión, Shah y Goldstein (2006) recomiendan informar de, al menos, una medida de fiabilidad calculada a partir de los parámetros estimados (por

ejemplo, alguna de las medidas propuestas por Bollen, 1989). En la mayoría de casos, alfa de Cronbach solamente puede considerarse como el límite inferior de la fiabilidad.

En general, la recomendación más extendida es evitar utilizar variables observables medidas con escasa fiabilidad y/o que presenten niveles de comunalidad bajos. Los factores resultantes deben interpretarse y etiquetarse de forma justificada desde un punto de vista teórico, aunque sea de forma tentativa, indicando en la aplicación qué variables observables se han utilizado y cuáles son sus cargas factoriales. No obstante, cabe señalar que no parece existir demasiado acuerdo respecto a qué valores concretos pueden ser considerados como cargas salientes o irrelevantes, estando esta cuestión fuertemente condicionada por el contexto de aplicación. Por un lado, algunos autores sugieren que las cargas factoriales estimadas ( $\hat{\lambda}_{ij}$ ) deberían obtener valores al menos de 0,5 e, idealmente, de 0,7 o superiores (Hair, Black, Babin, y Anderson, 2010). Por otro lado, otros autores están de acuerdo en aceptar valores de  $\hat{\lambda}_{ij} = 0,3$  - 0,4 como cargas adecuadas (Brown, 2015; Kline, 1994; Stevens, 2002); incluso se ha llegado a proponer como cargas salientes  $\hat{\lambda}_{ij} = 0,15$  (Cattell, 1978).

La cuestión de las características psicométricas es compleja puesto que la estabilidad de una solución factorial no depende solamente del nivel de fiabilidad-comunalidad de las variables observables, sino también del tamaño y heterogeneidad de la muestra y del grado de determinación de los factores (número de variables observables con cargas elevadas en el factor). Siguiendo este razonamiento, Ferrando y Anguiano (2010) sugieren intervenir sobre todo en estos dos últimos aspectos de la estabilidad de una solución factorial, ya que las medidas utilizadas habitualmente (ítems) contienen abundante error de medida, situación difícil de superar en el escenario de generación de modelos (carencias teóricas, propia naturaleza de los ítems: variables discretas, asimetría, etc.). Sin embargo, debería evitarse analizar variables-ítems con fiabilidad excesivamente baja y, siempre que sea posible, utilizar marcadores en cada

variable latente (ítems que han mostrado en investigaciones previas que son buenas mediciones del factor).

Sobre la recomendación general de utilizar variables observables con niveles de fiabilidad-comunalidad moderados o altos, conviene señalar que varios autores (Kruyen et al., 2013; Little et al., 1999) resaltan que las estrategias de selección netamente estadísticas resultan inadecuadas porque son “ciegas” al contenido de las variables, desde el punto de vista de la evaluación de la validez de constructo. Más concretamente, si seleccionamos variables observables solamente por su grado de correlación con otras variables (nivel de comunalidad alto) posiblemente estemos utilizando contenidos muy similares, lo que reduce drásticamente la posibilidad de alcanzar una buena representación del dominio evaluado. Según Little et al. (1999) asumir que las variables más interrelacionadas representan mejor al constructo que las menos interrelacionadas puede resultar engañoso en determinadas condiciones de selección, especialmente cuando el investigador no tiene un elevado *background* teórico. Por ejemplo, estos autores observaron en un estudio de simulación que la magnitud de la comunalidad y el número de variables por factor tenían un efecto reducido en la recuperación de la correlación entre factores. Para evitar estos posibles *sesgos de selección* conviene revisar si el contenido de las variables observables es lo suficientemente heterogéneo para representar adecuadamente al constructo evaluado. En palabras de Ferrando y Anguiano (2010, p. 23), “...*en el mundo real, la mayor parte de los ítems (y de los tests) no son medidas factorialmente puras. Con esfuerzo y tras un proceso de selección es posible llegar a obtener algunos ítems que son medidas casi puras. Estos ítems se denominan “marcadores” o “indicadores” en el lenguaje del AF. Sin embargo, la pretensión de que todos los ítems de un tests sean marcadores nos parece una hipótesis poco realista.*”



En línea con lo anterior, Ferrando y Anguiano (2010) argumentan que los términos error de variables observables redundantes no pueden ser independientes, lo que deriva en la aparición de factores adicionales que representan una parcela limitada-redundante del dominio evaluado y, posiblemente, una fuerte presencia de *cross-loading*. La recomendación para evitar estos problemas pasa, nuevamente, por la revisión del contenido previo de las variables observables. Para Brown (2015), el grado en el que la magnitud de los parámetros estimados resulta aceptable no puede determinarse exclusivamente en base a su dirección-signo y a su significación estadística. Esta cuestión depende del contexto de aplicación: por ejemplo, en investigación aplicada con AF a partir de cuestionarios, cargas factoriales o *cross-loading*  $\geq 0,3$  son considerados como suficientes para interpretar la carga como *saliente*, mientras que en aplicaciones AFC en las que se utilizan puntuaciones totales de escala en estudios de validez de constructo este proceder puede considerarse como demasiado liberal (p. 115).

En caso de eliminar variables observables tras la aplicación, se recomienda repetir AF en su ausencia ya que pueden producirse importantes modificaciones respecto a la solución inicial. Además, siempre y cuando sea posible, el investigador debe considerar también la validez de sus mediciones (validez aparente, validez convergente-discriminante, predictiva, etc., Fabrigar et al., 1999). En el caso de tests y escalas hay que tener en cuenta también que las respuestas a algunas variables pueden estar influidas por las respuestas a variables que han sido eliminadas, por lo que una aplicación posterior podría sufrir importantes modificaciones (Krueger et al., 2013). En otras palabras, las personas evaluadas mediante tests-escalas pueden variar sus respuestas a ciertas cuestiones en función de la omisión de otros aspectos evaluados, por lo que se recomienda poner a prueba la versión reducida en nuevas muestras.

Por último, actualmente la mayoría de las aplicaciones AF siguen un enfoque lineal, en el sentido de asumir la linealidad de las mediciones y de la relación entre variables observables

y latentes. En el caso de ítems de respuesta graduada (especialmente con 5 categorías de respuesta o más), aplicar AF desde este enfoque resulta adecuado si los niveles de asimetría de las variables observables se encuentran entre -1 y 1. Incluso con datos dicotómicos puede utilizarse el modelo lineal si los índices de dificultad oscilan entre 0,4 y 0,6. Cuando las mediciones tienen distribuciones más extremas, sería más adecuado estimar modelos no lineales de AF (Ferrando y Anguiano, 2010).

### *Recuperación de cargas factoriales bajas*

Retomando algunas de las cuestiones comentadas en el prólogo de esta tesis, para lo que recordamos la existencia de varios estudios Monte Carlo que han puesto el foco precisamente en la recuperación de factores a partir de la simulación de cargas poblacionales bajas ( $\lambda_{ij}$ ). En el marco del AFE, las magnitudes simuladas más pequeñas de  $\lambda_{ij}$  en los diferentes estudios han sido de 0,5 (MacCallum, Tucker, y Briggs, 2001), 0,4 (Briggs y MacCallum, 2003; Little et al., 1999), y 0,2 (MacCallum et al., 1999; Mundfrom et al., 2005; De Winter, Dodou, y Wieringa, 2009). En el marco del AFC, las magnitudes simuladas más pequeñas de  $\lambda_{ij}$  han sido 0,5 (Wolf, Harrington, Clark, y Miller, 2013), 0,4 (Enders y Bandalos, 2001), entre 0,3 y 0,4 (Heene, Hilbert, Draxler, Ziegler, y Bühner, 2011; Ximénez, 2009, 2016), 0,25 (Ximénez, 2006, 2007), y 0,2 (Gagné y Hancock, 2006). En general, estos estudios vienen a confirmar que la magnitud de  $\lambda_{ij}$ ,  $n$  y  $N$  están entre las variables más influyentes en relación a la recuperación de parámetros. De hecho, todos estos estudios muestran la existencia de un efecto compensatorio entre variables (Fabrigar et al., 1999; MacCallum et al., 1999; Marsh, Hau, Balla, y Grayson, 1998). Por ejemplo, la debilidad de  $\lambda_{ij}$  puede ser parcialmente compensada por un número suficiente de variables observables por factor o mediante un número suficiente de

observaciones, incluso bajo condiciones en las que se han simulado las magnitudes de  $\lambda_{ij}$  más bajas. En contraposición, las combinaciones más críticas de estas variables (magnitudes más bajas de  $\lambda_{ij}$ ,  $n = 3$  o  $4$  y  $N \leq 200$ ), producen un elevado incremento de soluciones no convergentes e impropias (por ejemplo, casos *Heywood*), y unos niveles de recuperación de parámetros inaceptables.

Cuando las magnitudes simuladas de  $\lambda_{ij}$  fueron de  $0,4 - 0,5$ , los resultados de estos estudios reflejaron una buena recuperación de parámetros en la mayoría de soluciones evaluadas, incluso con un número relativamente pequeño de variables observables por factor y/o de observaciones (por ejemplo, en Briggs y MacCallum, 2003). Magnitudes simuladas de  $\lambda_{ij}$  por debajo de  $0,4$  producen un incremento de soluciones no convergentes y un peor comportamiento del proceso de estimación (Ximénez, 2006, 2007). A partir de magnitudes simuladas de  $0,2$ , De Winter et al. (2009) mostraron que para obtener una recuperación de parámetros adecuada se necesitan muestras compuestas por más de 750 observaciones y  $n = 6$  (en modelos de dos factores). Gagné y Hancock (2006) informaron de niveles de recuperación similares con  $N = 1.000$  y  $n \geq 6$  en modelos de tres factores. No obstante, debe tenerse en cuenta también el efecto de otras características de los modelos evaluados. Por ejemplo, la recuperación de parámetros mejora considerablemente cuando factores simulados a partir de magnitudes bajas de  $\lambda_{ij}$  presentan correlación con otros factores dentro del modelo (Ximénez, 2006, 2007), o en aquellos modelos compuestos por un número reducido de factores (De Winter et al., 2009).

En resumen, todos estos trabajos han puesto de manifiesto que la utilización generalizada de puntos de corte en los valores estimados de las cargas factoriales en el proceso de selección de variables observables puede dejar fuera factores que son recuperados con precisión. Podría decirse que a partir de cargas poblacionales  $\geq 0,3 - 0,4$  la recuperación de parámetros podría

funcionar relativamente bien en contextos aplicados. No obstante, estos estudios han mostrado que la recuperación final dependerá de otros aspectos del modelo y de la aplicación, al existir un efecto compensatorio entre variables, dependiendo a su vez del grado en el que los modelos estén correctamente especificados. El problema es que el investigador aplicado desconoce por regla general la magnitud de las cargas poblacionales que está estudiando, solo puede tomar este tipo de decisiones en base a los valores estimados.

#### *Número de variables latentes*

Seleccionar el número de variables latentes cuando se aplica AF requiere que el investigador establezca un cierto equilibrio entre la parsimonia del modelo y su adecuación para representar el dominio que se pretende medir. Es decir, se deben buscar modelos compuestos por relativamente pocos factores, pero suficientes y adecuados para reflejar el constructo evaluado (Fabrigar et al., 1999). En AFE la selección de factores se orienta tanto desde el *background* teórico/empírico como desde los resultados obtenidos tras estimar el modelo a partir de los datos, y es recomendable utilizar de forma combinada varias técnicas para orientar la toma de decisiones, como *scree-plot*, análisis paralelo - AP, o *minimum average partial* - MAP (Izquierdo et al., 2014). Parte de estas recomendaciones puede extenderse a la aplicación AFC. Si bien las variables latentes se deben especificar como hipótesis sustantivas antes de estimar el modelo, la práctica convencional revisada indica que la generación de modelos es un escenario de aplicación frecuente, por lo que en ocasiones puede ser razonable orientar algunas decisiones sobre el número definitivo de factores también desde los resultados (al menos ciertas decisiones finales).

### *Replicabilidad*

A pesar de no ser una práctica habitual, sería deseable que las distintas aplicaciones AF suministrasen las matrices de varianzas-covarianzas o de correlaciones con las que se han realizado los análisis, así como los parámetros estimados y los errores estándar. La posibilidad de que otros investigadores puedan re-analizar la estructura factorial a partir de los mismos datos es especialmente relevante en este marco de trabajo, caracterizado por la cantidad de decisiones que se deben tomar (Fabrigar et al., 1999; Izquierdo et al., 2014; Jackson et al., 2009; Kline, 2015; McDonald y Ho, 2002). Si la publicación no ofrece espacio suficiente para informar de las de datos, entonces sería preciso que los datos estuviesen disponibles a través de alguna dirección de contacto, y que se alcanzara un mayor compromiso de transparencia respecto a los datos, compromiso que parece estar aumentando con el tiempo. Cabe señalar la falta de información suministrada en la literatura revisada sobre las cargas factoriales de los modelos estimados, lo que dificulta valorar el alcance de las recomendaciones planteadas sobre selección de variables observables.

### *Hacia un desarrollo teórico apoyado en evidencias científicas*

Según MacCallum y Austin (2000), cuando una aplicación AFC pretende validar la estructura factorial hipotética de una determinada escala (validez de constructo), es necesario realizar evaluaciones adicionales en busca de nuevas evidencias, por ejemplo, desarrollando versiones acortadas de la escala, realizando estudios multirasgo-multimétodo (MTMM), estudios de invarianza temporal-distintos grupos, o evaluando la validez de constructo en diferentes contextos y a partir de nuevas muestras. En este sentido, también hay que incluir las fuentes de evidencia relacionadas con la evaluación con la capacidad predictiva de los modelos, como se comentó en el apartado 1.2. Cuando la aplicación AFC no permite *confirmar* la

estructura interna de la escala, una posibilidad es utilizar los resultados para futuras re-evaluaciones (por ejemplo, omitiendo ítems con *cross-loading*). Desde este enfoque, la aplicación AFC se desarrollaría desde una aproximación hipotético-deductiva, más acorde con el desarrollo de teorías científicas *in progres*, podríamos decir.

El sesgo confirmatorio resulta especialmente problemático en aplicaciones AF y SEM puesto que lo razonable es aceptar la existencia de modelos alternativos con los mismos niveles de consistencia empírica que el modelo evaluado. La recomendación es utilizar estrategias y métodos que permitan comparar entre modelos alternativos, desplazando el escenario de generación de modelos (MG) hacia un escenario de comparación de modelos (AM). No obstante, hay que incidir en que la comparación de modelos alternativos no debe estar dirigida exclusivamente hacia la comparación entre modelos anidados (aquellos en los que los parámetros de un modelos son un subconjunto de parámetros de otro de los modelos analizados), como muestra la práctica convencional, sino que las alternativas a comparar deben estar fundamentadas a nivel substantivo. Si bien la comparación de modelos anidados tiene cierta utilidad, no permiten identificar ni evaluar la posible existencia de modelos *cualitativamente* distintos que podrían ser alternativas más adecuadas para explicar los datos (Jackson et al., 2009; MacCallum y Austin, 2000; Shah y Goldstein, 2006). De esta cuestión también advirtieron McDonald y Ho (2002) refiriéndose a la generación mecánica de modelos alternativos *post hoc* a partir de cambios sugeridos por los índices de modificación. Los modelos alternativos (anidados o no) deberían ser propuestos *a priori* por el investigador, y las re-especificaciones de los modelos evaluados deberían estar justificadas teóricamente. En el caso de aplicaciones estrictamente confirmatorias (SC) se debe concluir sobre si los resultados apoyan o no al modelo teórico original. Si la aplicación tiene un carácter más exploratorio, o si se han realizado modificaciones sobre el modelo inicial, las conclusiones deben ser más

tentativas (Boomsma, 2000). Por otro lado, el efecto estadístico de los errores correlacionados es el mismo que el de los *cross-loading*, aunque no significan lo mismo sustantivamente (Shah y Goldstein, 2006). Incluir parámetros de correlación entre errores suele mejorar el ajuste del modelo, por lo que este tipo de estrategias *post hoc* debería evitarse salvo justificación teórica.

Otro aspecto relacionado con el sesgo confirmatorio es que buena parte de las aplicaciones revisadas fueron realizadas con una sola muestra, por lo que resulta recomendable utilizar criterios *cross-validation* (por ejemplo, ECVI de Browne y Cudeck, 1989: en Fabrigar et al., 1999; MacCallum y Austin, 2000; Shah y Goldstein, 2006) o dividir las muestras en dos partes para realizar dos aplicaciones consecutivas. Siempre que sea posible, sería recomendable repetir las aplicaciones con nuevas muestras.

Un aspecto crítico relacionado con la invarianza temporal de los parámetros y con la posibilidad de establecer relaciones causales, se refiere a la preeminencia de los estudios de carácter transversal. En general, en este tipo de estudios no se informa sobre cómo influye la temporalidad entre el “suceso A” y el “suceso B”, en términos de causalidad. Es decir, se asume implícitamente que el tiempo entre ambos sucesos permite inferir causalidad, que el efecto del “suceso A” sobre el “suceso B” no varía en función del tiempo. Esta cuestión es compleja y en muchos casos no puede resolverse empíricamente de forma directa. Una forma de aproximarse a esta problemática es que los investigadores argumenten y justifiquen explícitamente que el tiempo entre el “suceso A” y el “suceso B” es lo más cercano posible (idealmente, que el “suceso B” ocurra inmediatamente después del “suceso A”). Si no se puede asumir esta condición, la estimación de los *efectos* en un estudio transversal puede estar fuertemente sesgada por omisión de sucesos o procesos no tenidos en cuenta (MacCallum y Austin, 2000; McDonald, 1999). En este sentido, esta reflexión puede servir para que los investigadores se decanten más por un estudio longitudinal que por un estudio transversal, tanto en la revisión de

la literatura previa como en el diseño de nuevos estudios. En el contexto de aplicación exclusivamente SEM, McDonald y Ho (2002) realizan una reflexión similar, destacando la importancia de explicitar la presencia o ausencia tanto de las relaciones directas entre variables latentes como las no directas (precedencia temporal vs. simultaneidad o correlación).



## 1.4. Evidencias sobre la varianza común de las variables latentes: *clústers* independientes y modelo de independencia

### 1.4.1. Uso generalizado de índices de ajuste del modelo multidimensional

Una diferencia fundamental entre AFE y AFC es que el investigador sigue distintas estrategias para aislar los factores principales que componen la estructura del constructo evaluado, asumiendo la existencia de una *estructura simple* (Thurstone, 1947), o de una estructura formada por *clústers independientes* (McDonald, 1999; McDonald y Ho, 2002). Dentro del marco del AFE la rotación ha sido la estrategia más utilizada. Mediante la elección de alguna técnica de rotación, el investigador busca identificar con mayor claridad cuáles son las cargas factoriales primarias o salientes, minimizando a su vez las cargas secundarias (idealmente, tratando de equipararlas a cero). Por su parte, cuando se aplica un modelo AFC la especificación del modelo inicial normalmente excluye la posibilidad de encontrar *cross-loading*, dado que el investigador hipotetiza que cada variable observable representa únicamente a un factor dentro de la estructura multidimensional (es decir, el investigador normalmente hipotetiza la existencia de clústers independientes). En este contexto, se sustituye una estrategia analítica (*data-driven*) por una confirmatoria (*theory-driven*), en la que el investigador fija previamente a cero todas las relaciones de las variables observables fuera del clúster. Desde este punto de vista, la re-especificación de la estructura factorial mediante la inclusión de medidas multidimensionales (identificación de *cross-loadings*, o de términos error correlacionados), implica la revisión teórica del modelo o constructo evaluado.

El concepto de estructura simple propuesto por Thurstone es una propiedad que implica que, para un conjunto de soluciones matemáticas equivalentes, la solución con la mejor

estructura simple será aquella más fácil de interpretar, con mayor significación teórica y la más replicable. Este concepto hace referencia a aquellas soluciones en las que cada factor se define por un subconjunto de variables observables con cargas elevadas en comparación con otras variables observables y en las que cada una de ellas presenta cargas elevadas solamente en un *subconjunto* de factores. Se trata, por tanto, de estructuras de baja complejidad factorial. En consecuencia, dentro del número indeterminado de soluciones existentes, el investigador debe rotar los factores en el espacio multidimensional con el fin de obtener la solución con la mejor estructura simple (Brown, 2015; Fabrigar et al., 1999; Kline, 2015). Thurstone formuló las siguientes condiciones que definen la propiedad de estructura simple (McDonald, 1999, pp. 179-180):

- Cada fila de la matriz de cargas factoriales ( $\Lambda_x$ ) debe incluir al menos un elemento igual a cero.
- Cada columna debe tener al menos  $r$  elementos iguales a cero.
- Para cada par de columnas de  $\Lambda_x$  debe haber al menos  $r$  variables con cargas iguales a cero en una columna y distintas de cero en la otra columna.
- En el caso de que  $r > 3$ , para cada par de columnas debe haber una elevada proporción de variables con cargas = 0 en ambas columnas.
- Para cada par de columnas debe existir una pequeña proporción de cargas  $\neq 0$  en ambas columnas.

Siguiendo a McDonald (1999), en el marco del AFC se considera que una condición suficiente para garantizar la identificabilidad de los modelos es que las cargas factoriales formen clústers independientes<sup>1</sup>. El concepto de clúster independiente es una extensión del concepto de estructura simple propuesto por Thurstone, que no debe confundirse ya que no son sinónimos: en términos de la “*estructura más simple posible*”, las variables observables pueden saturar en más de una variable latente, mientras que un clúster independiente estará formado por variables observables con cargas salientes *únicamente* en dicho factor. En consecuencia, la estructura simple no garantiza la identificabilidad del modelo mientras que los clústers independientes sí. La aplicación más común de AFC suele garantizar la identificabilidad de los modelos ya que el investigador tiende a fijar a cero la carga factorial de cada variable observable en el resto de factores que componen el modelo, permitiendo la estimación libre de dicho parámetro en el factor que representa (hipotéticamente). En otras palabras, proponer modelos causales de medida implica generalmente hipotetizar la existencia de clústers independientes, lo que garantiza la identificabilidad del modelo. Las condiciones algebraicas generales que permiten establecer la identificabilidad del modelo son las siguientes, en donde la carga factorial exclusiva de las variables observables en uno solo de los factores especificados es una característica común: 1) para cada factor existen al menos tres variables observables, con cargas  $\neq 0$  en el clúster y con cargas  $= 0$  en el resto de clústers, y 2) para cada factor existen al menos dos variables observables, con cargas  $\neq 0$ , que tienen cargas  $= 0$  en el resto de factores, y

---

<sup>1</sup> En términos AFC un clúster independiente puede conceptualizarse como una medida unidimensional de algún aspecto del constructo, si bien lo que se pone a prueba mediante el test  $\chi^2_{\text{Null}}$  es si el clúster tiene suficiente varianza común, no su unidimensionalidad (esta última puede ser asumida, en ausencia de parámetros multidimensionales). Por tanto, preferimos hablar de estrategia de *pre-evaluación de la factorabilidad* en lugar de evaluación de la *unidimensionalidad* para evitar equívocos conceptuales y solapamientos no deseados con conceptos de otras áreas de investigación (por ejemplo, la TRI).

cualquier factor representado solamente por dos variables observables correlaciona con otros factores.

El concepto de clústers independientes o de *modelo restringido* (en menor medida el de estructura simple en el marco del AFE o *modelos no restringidos*, aunque también es aplicable), permite incidir en la cuestión del *pseudo*-aislamiento comentada en los apartados anteriores. Siguiendo a McDonald y Ho (2002), el concepto de clústers independientes permite establecer las condiciones algebraicas en las que el investigador pone a prueba variables latentes que representan conceptos unidimensionales hipotéticos (condiciones 1 y 2, que McDonald denominó *independent-cluster basis*). Dichas condiciones están directamente vinculadas con la condición de *pseudo*-aislamiento, que es establecida de forma previa a la evaluación de la consistencia empírica (el investigador fija a cero las cargas que apuntan fuera del clúster durante el proceso de especificación, siguiendo una estrategia confirmatoria incluso en el escenario de generación de modelos - MG). Como indica McDonald (1999, p. 178): “*Fortunately, the needed conditions often coincide with hypotheses that reflect the design of the test*”.

Por tanto, el planteamiento de clústers independientes forma parte de la propia naturaleza del AFC en términos causales. De hecho, más allá de definir condiciones de identificabilidad, plantea la necesidad de obtener evidencias empíricas de cada clúster. La evaluación de las variables latentes se realiza en condiciones de *pseudo*-aislamiento si se cumple que dichas variables son independientes del error de medida, ya que permite descartar el efecto de factores no tenidos en cuenta dentro del modelo (se asume que  $COV(\xi_j, \delta_{ij}) = 0$ ). Desde esta perspectiva, el análisis en términos causales está implícito en la propia existencia y naturaleza de cada una de las variables latentes hipotetizadas, por lo que la evaluación empírica de los modelos AFC debería comenzar en este punto, y no concretarse, inferirse o generalizarse a partir del ajuste del modelo multidimensional. El punto de partida debería ser la obtención de evidencias del

sistema de ecuaciones más simple, esto es, asumiendo la condición de *pseudo*-aislamiento a nivel matemático, y después añadir nuevas fuentes de variación. Esta estrategia de análisis ha sido concretada por Jöreskog y Sörbom (1993), como se detalla más adelante en el apartado 1.4.3. Por supuesto, la condición de *pseudo*-aislamiento podrá ser asumida con garantías en la medida en la que se replique la evaluación en nuevos estudios ( $C = 1, 2, 3, \dots$ ).

En el caso de modelos que incluyen factores VCL, la aplicación de esta lógica pre-evaluativa se hace más patente y necesaria. Se precisa tener algún tipo de evidencia sobre la consistencia de la variable latente como hipótesis sustantiva. La estructura multidimensional se explica a partir de diversos clústers independientes o grupos de variables. Por su parte, los índices de ajuste que se utilizan habitualmente son promedios que se refieren al modelo completo o multidimensional. En estas circunstancias, el buen ajuste del modelo multidimensional puede llegar a compensar desajustes “locales” en alguno de los clústers independientes que lo forman. De hecho, al solicitar los índices de modificación (MI) los investigadores aplicados se encuentran a menudo ante múltiples sugerencias de re-especificación del modelo, incluso en estructuras bien ajustadas a nivel “global”<sup>2</sup>.

La selección arbitraria de “buenos indicadores” desde un enfoque puramente psicométrico descarta la posibilidad de someter a prueba la *entidad* de algunas variables latentes que pueden ser importantes teóricamente, y el ajuste del modelo multidimensional no es una evidencia suficiente de dicha entidad. La práctica habitual en AFC parece haber estado garantizando la entidad sustantiva de los factores a nivel empírico mediante la selección de indicadores con cargas factoriales altas, extrapolando el buen ajuste global a los a cada uno de los clúster independiente, cuando en realidad se trata de medidas promediadas de ajuste. Y es

---

<sup>2</sup> Los términos “local” y “global” se utilizan en referencia a la evaluación de un clúster independiente y a la evaluación del conjunto de clústers independientes o modelo multidimensional, respectivamente.

posible que esta práctica consiga depurar muchos de los modelos propuestos, eliminando ruido que no necesita ser puesto a prueba, si bien cabe señalar que este tipo de estrategias parecen ir en contra de la propia lógica causal de los modelos, además de resultar ciertamente opaca o *ciega*, como han propuesto varios de los autores mencionados en el apartado precedente. Por otro lado, este proceder parece sustentarse o centrarse en la *variable latente como problema*, por así decir, evitando en cierta medida el cuestionamiento de las condiciones de aplicación necesarias para el uso de la herramienta.

En línea también con varias de las recomendaciones realizadas por los autores revisados, una consecuencia positiva de la aplicación de la estrategia de pre-evaluación propuesta es que puede potenciar la comparación de modelos cualitativamente distintos (no solamente modelos alternativos-anidados mediante estrategia comparativa *post hoc*), lo que redundaría en una mejor aproximación al contenido del constructo evaluado. El sesgo de selección (y su “validación” a nivel de ajuste global) nos lleva a suponer que varios conceptos o subdominios de los constructos evaluados no han sido siquiera puestos a prueba. En el caso de factores VCL, si dichos subdominios fuesen puestos a prueba parece razonable pensar que alguno de ellos podría obtener evidencias suficientes sobre su entidad, al menos, siguiendo las propuestas que se desarrollan en el presente trabajo. En ese caso, cabría esperar una mayor presencia de modelos cualitativamente distintos compitiendo por explicar el constructo evaluado, contribuyendo así a reducir el sesgo confirmatorio y la explicación-medición de fenómenos en términos causales ( $\hat{\Sigma}_{B,C}$ ).

#### 1.4.2. Tipo de error de especificación y sensibilidad de los índices descriptivos de bondad de ajuste

El concepto de clústers independientes permite realizar una distinción adicional, relacionada con el tipo de variables observables y su vinculación con la estructura factorial de la que forman parte. Se trata de la distinción entre variables observables factorialmente simples y factorialmente complejas (McDonald, 1999, p. 179). En una estructura formada por clústers o grupo de variables independientes, se puede considerar que cada variable latente es factorialmente simple al representar únicamente a un factor. Por su parte, la especificación de medidas multidimensionales (generalmente, como consecuencia de procesos de re-especificación mediante índices de modificación (MI), según refleja la práctica convencional del AFC), puede considerarse como factorialmente compleja. En el primer caso, el error de especificación se hará patente cuando en el modelo evaluado se especifiquen clústers de variables observables escasamente correlacionadas, ya que el modelo especificará un número mayor de parámetros del que es necesario estimar, además de proponer hipótesis sustantivas que no tienen consistencia empírica. Se trata de un tipo de error de especificación *por exceso* de parámetros.

En el segundo caso, el error de especificación vendrá determinado por la falta de especificación de parámetros (*por omisión*), especialmente en el caso de *cross-loading* o *double-loading* (se puede entender que la presencia de errores correlacionados es consecuencia de cargas factoriales salientes en más de un factor que están sin especificar en el modelo, especialmente cuando las cargas son muy altas o también por la presencia de colinealidad). La no especificación de los parámetros relacionados con la correlación entre factores también es un error de especificación de este segundo tipo.

La mayoría de aplicaciones AFC conceden una relevancia prácticamente absoluta a la evaluación del ajuste del modelo mediante los denominados índices descriptivos de bondad de ajuste (RMSEA, SRMR, NNFI, CFI, etc.) y mediante estrategia inferencial a partir de la prueba  $\chi^2$ . Además, la revisión de las prácticas de publicación comentada en el apartado anterior (a partir de ahora, la denominaremos *revisión de las prácticas de publicación* o RPP), muestran una mayor preeminencia de este tipo de evaluaciones frente a la evaluación de la validez de constructo de los modelos. El problema fundamental es que este tipo de evaluación, además de haber recibido varias e importantes críticas en los últimos años (Barret, 2007; Fan y Sivo, 2005, 2007), es insensible a la presencia de variables observables con cargas factoriales bajas (error por *sobreparametrización*), es decir, a la presencia de factores o clústers VCL. En este sentido, Heene et al. (2011) han mostrado que los valores de  $\chi^2_0$ , RMSEA y SRMR decrecen a medida que disminuye la comunalidad (en el caso de CFI los valores se aproximan más a 1). Eliminar variables observables medidas con escasa fiabilidad no produce ninguna mejoría en el ajuste (Brown, 2015; Kline 2015). En otras palabras, *en ausencia de otros errores de especificación*, los índices descriptivos de ajuste<sup>3</sup> no son capaces de detectar el error por sobreparametrización. Los índices descriptivos, tal y como muestra la literatura, tienen cierta capacidad para identificar errores de especificación del segundo tipo, es decir, son sensibles a la omisión de parámetros en el modelo cuyo valor poblacional es distinto de cero (*infraparametrización*).

Cuando se utiliza AFC en contextos aplicados, los investigadores por norma general desconocen el valor de los parámetros a nivel poblacional que subyace a los datos. En consecuencia, debemos recurrir a los índices descriptivos de ajuste para decidir si existe ajuste entre el modelo hipotetizado y los datos disponibles (Olsson, Foss, Troye, & Howell, 2000). La

---

<sup>3</sup> Por simplicidad, y siguiendo la clasificación propuesta por Brown (2015, pp. 67-75) denominaremos así a todas las medidas de bondad de ajuste (tanto las propiamente descriptivas, las comparativas y la estrategia inferencial  $\chi^2$ ).



utilización de estos índices se ha extendido enormemente en la investigación aplicada durante los últimos años, sirviendo como criterio para la aceptación y publicación de modelos factoriales en numerosas revistas (el uso de los índices descriptivos viene acompañado de una serie de recomendaciones sobre los puntos de corte que se deben superar como medida de adecuación o de aproximación). Especialmente influyente en este campo han sido los trabajos de simulación de Hu y Bentler (1998, 1999). En estos trabajos se elaboró una estrategia para la evaluación del ajuste de modelos AFC (estrategia “dos-índices”) en la que se diferenciaba, por un lado, a *Standardizer Root Mean Residual* (SRMR) como el índice con más capacidad para identificar covarianzas entre factores incorrectamente especificadas ( $\phi_{jk}$ ) y, por otro lado, a un grupo de índices (*Non-normed Fit Index* - NNFI, *Relative Noncentrality Index* - RNI, *Comparative Fit Index* - CFI, *Root Mean Squared Error of Approximation* - RMSEA, entre otros), como los que tienen mayor capacidad o sensibilidad para identificar cargas factoriales incorrectamente especificadas ( $\lambda_{ij}$ ). En estos trabajos los autores evaluaron la sensibilidad de todos estos índices bajo condiciones o diseños de *infraparametrización*, esto es, en condiciones en las que el error de especificación es del segundo tipo propuesto (omisión o fijación a cero de parámetros cuyos valores poblacionales son distintos de cero). Otro aspecto a señalar es que las cargas factoriales simuladas fueron bastante elevadas por lo que resulta todavía más difícil su generalización al campo aplicado.

Actualmente, existen importantes limitaciones y críticas sobre la parcialidad de los índices descriptivos de ajuste (por ejemplo, Barrett, 2007; Fan y Sivo, 2005, 2007; Yuan, 2005). De hecho, los propios Hu y Bentler (1999) ya advertían en sus conclusiones de la necesidad de evaluar el comportamiento de este tipo de índices en una tipología amplia de modelos y de condiciones. Mulaik (2009) mantiene una postura más o menos intermedia o de compromiso entre la utilización de la prueba  $\chi^2$  y la utilización de los índices que no siguen una estrategia

inferencial. Para este autor, los modelos que se encuentran en las etapas iniciales de investigación pueden simplificarse mediante aproximaciones empíricas más gruesas, utilizando la información sobre el grado de aproximación para valorar si el investigador se encuentra en el camino correcto. Esta postura se adapta bastante bien al contexto de generación de modelos (MG) que está presente en muchas de las aplicaciones AFC actuales (tal y como se desprende de los resultados de la RPP).

Nuestro punto de vista es coincidente con el propuesto por Mulaik (ibíd.), en el sentido de que si bien los índices descriptivos presentan importantes limitaciones, todavía pueden ser útiles para evaluar el ajuste de los modelos. A pesar de las críticas recibidas por su uso excesivamente generalizado, la cuestión fundamental que se quiere destacar aquí es que dichos índices son sensibles a errores de especificación por omisión de parámetros y no por selección de variables observables poco correlacionadas, que es el tipo de situación que interesa identificar con garantías en el presente trabajo.

Nuestro planteamiento es que el uso de índices descriptivos de ajuste tiene más sentido en una segunda etapa, tras el proceso de pre-evaluación del factor VCL o clúster independiente de variables. Superada esta evaluación inicial, los índices de ajuste pueden ser de interés. Otra forma de expresar lo anterior es dar prioridad a la estrategia inferencial, como sugiere Barrett (2007), pero sin descartar la información que nos ofrecen las medidas de ajuste descriptivo. En una primera fase se realizaría una prueba inferencial como principal fuente de evidencia sobre la consistencia empírica de la varianza común de cada clúster (evaluando la presencia de error de especificación por *sobreparametrización*), y en una segunda fase se evaluaría la presencia de errores de especificación por *infraparametrización* a partir de los índices descriptivos. Esta última evaluación se puede dividir también secuencialmente, realizando un primer análisis en cada clúster comprometido, y un segundo análisis sobre el modelo multidimensional. En las

fases finales del análisis se puede realizar la prueba  $t$  bajo la hipótesis nula de que las cargas factoriales son cero para interpretar con mayor precisión cuáles son los parámetros estimados más importantes y cuáles tal vez habría que depurar, aunque siendo precavidos respecto al Error Tipo I (Mulaik, 2009).

Asumiendo la existencia de clústers independientes a nivel sustantivo, en la primera fase de evaluación del modelo “local” la identificación de *sobreparametrización* se realiza en ausencia de errores de especificación por omisión, salvo tal vez la presencia de errores correlacionados fruto de la existencia de colinealidad entre variables observables que pertenecen al mismo clúster. Esta situación es óptima para “poner a prueba” los factores en términos de varianza común, lo que permitirá obtener evidencias que orienten la inclusión de factores VCL dentro del modelo, o la evaluación de las condiciones de aplicación, evitando así el sesgo de selección y la utilización arbitraria de puntos de corte en los valores de las cargas factoriales. La utilización de índices descriptivos de ajuste en esta fase puede ser de interés para identificar la presencia de errores correlacionados y, también, para ayudar a tomar decisiones en aquellos casos en los que la varianza común se encuentre *en el límite*.

Siguiendo la lógica expuesta, con las estrategias habituales de la práctica convencional del AFC la presencia de factores VCL sustantivos puede ser desestimada *antes de tiempo* (sin evidencias empíricas) en el proceso de selección de variables observables. A la inversa, puede ocurrir que en determinadas condiciones el AFC no sea una herramienta lo suficientemente sensible para la detección de este tipo de factores. Por último, si las condiciones son suficientes para la detección de factores VCL “verdaderos” y aun así no se acumulan evidencias de consistencia empírica, la pre-evaluación del clúster independiente puede prevenir la inclusión de factores “falsos” enmascarados tras una adecuada medida de ajuste del modelo multidimensional (y lo que resulta más preocupante, puede prevenir potenciar una mejoría en

el ajuste por la especificación de factores “falsos”). Como Schermelleh-Engel, Moosbrugger, y Müller (2003, p. 33) han señalado, “*a good model fit may result either from a correctly specified model or from a highly overparameterized model*”. Por tanto, todas estas situaciones plantean la necesidad de pre-evaluar los clústers comprometidos por mediciones realizadas con fiabilidad limitada. Y la estrategia de evaluación que proponemos en este trabajo como mejor opción se basa en la *prueba inferencial  $\chi^2$  sobre el modelo de independencia*, como se detalla en el siguiente apartado.

#### 1.4.3. Evaluación del modelo de independencia como fuente de evidencia

El *modelo de independencia* ( $\Sigma_{\text{Null}}$ ), también denominado modelo nulo o base, es aquel cuya matriz poblacional de varianzas-covarianzas es diagonal, es decir, es un modelo en el que las distintas variables observables que lo forman no tienen relación entre sí. El modelo de independencia también puede expresarse como un modelo factorial en el que todas las cargas factoriales están fijadas a cero, en donde los únicos parámetros a estimar son las unicidades de las variables observables. Por tanto, los elementos de la diagonal de la matriz empírica se pueden calcular bajo la hipótesis expuesta en (8) ya que las covarianzas poblacionales son estadísticamente iguales a cero, lo que implica que la única varianza observada es unicidad (Mulaik, 2009, p. 326):

$$\hat{\Sigma}_{\text{Null}} = [\text{diag}(\mathbf{S})] = \mathbf{0}\Phi\mathbf{0}' + \Psi^2 = \Psi^2 \quad (8)$$

El valor  $\chi^2$  asociado al modelo de independencia ( $\chi^2_{\text{Null}}$ ) puede expresarse según la ecuación (9) y puede calcularse mediante la ecuación (10), por ejemplo a partir del método de estimación ML:

$$\chi^2_{\text{Null}} = (N - 1)F(\mathbf{S}; \hat{\Sigma}_{\text{Null}}) \quad (9)$$

$$F_{\text{ML}} = \ln \hat{\Sigma}_{\text{Null}} - \ln |\mathbf{S}| + \text{tr}(\hat{\Sigma}_{\text{Null}}^{-1} \mathbf{S}) - n \quad (10)$$

$$F(\mathbf{S}; \hat{\Sigma}_{\text{Null}}) = F_{\text{ML}}$$

Dado que solamente se deben estimar los elementos de la diagonal (unicidades), para  $n$  variables observables los grados de libertad del modelo de independencia son  $gl = n(n-1)/2$ . A partir de la información anterior se puede elaborar una prueba inferencial mediante el estadístico  $\chi^2_{\text{Null}}$  con los grados de libertad del modelo para contrastar la hipótesis nula de que las covarianzas entre las variables observables son cero en la población (o que las cargas factoriales son cero en la población). Esta estrategia aplicada a la información contenida en el modelo “completo” o multidimensional, genera valores de  $\chi^2_{\text{Null}}$  bastante elevados, salvo en raras excepciones (Mulaik, 2009), y su valor se utiliza en alguno de los índices descriptivos de ajuste más utilizados como CFI y NNFI.

En este sentido, un claro precursor del uso del valor de  $\chi^2_{\text{Null}}$  para evaluar la bondad de ajuste se encuentra en el trabajo de Bentler y Bonett (1980), a partir del cual se popularizó el uso de índices de ajuste comparativo (*Incremental Fit Indices*), apoyándose en el trabajo previo de Tucker y Lewis (1973). Este trabajo, que es uno de los más relevantes y más citados dentro de este campo de investigación (Marsh, Hau, y Grayson, 2005), planteaba la conveniencia de desarrollar índices de ajuste que fueran relativamente insensibles al tamaño de la muestra, superando así una de las principales limitaciones de  $\chi^2$ . Otra característica deseable de este tipo

de índices es que se encontrasen traducidos a una métrica interpretable y comparable en términos absolutos, a partir del establecimiento de puntos de corte. Para ello, los autores plantearon elaborar un índice que permitía evaluar la bondad de ajuste en un continuo entre 0 y 1, entendiendo que el valor 0 reflejaría el ajuste a un *modelo base o nulo* ( $\hat{\Sigma}_{\text{Null}}$ ) entendido como el peor de los resultados posibles, mientras que el valor 1 reflejaría un ajuste óptimo. Conviene señalar que Bentler y Bonett (1980, p. 596) indicaron que pueden existir distintos tipos de modelos base, si bien el caso más general (y el que desarrollan estos autores en su trabajo) es el propuesto en (8), ya que es el más frecuente en los distintos trabajos de investigación. En la extensa revisión sobre índices de bondad de ajuste que realizan Marsh et al. (2005, p. 291), también se indica que la utilización de modelos base alternativos está bastante menos extendida (y aceptada) en aplicaciones SEM que el modelo base propuesto por Bentler y Bonett. Además, el valor de  $\chi^2$  que ofrece el software especializado es el valor  $\chi^2_{\text{Null}}$  propuesto.

La introducción del valor de  $\chi^2_{\text{Null}}$  para la evaluación del ajuste de modelos factoriales se ha desarrollado desde la perspectiva de los *incremental fit indices* propuesta originalmente por Bentler y Bonett. Esta estrategia ha dado lugar a varios índices descriptivos: NFI (Bentler y Bonett, 1980), TLI o NNFI (Tucker y Lewis, 1973), RFI (Bollen, 1986), IFI (Bollen, 1989, 1990), RNI (McDonald y Marsh, 1990), y CFI (Bentler, 1990)<sup>4</sup>. Este uso del valor de  $\chi^2$  del  $\hat{\Sigma}_{\text{Null}}$  se caracteriza por dos aspectos que son relevantes desde el punto de vista del presente trabajo. El primero es que el valor de estos índices de ajuste se calcula realizando algún tipo de comparación entre el valor de  $\chi^2$  del modelo evaluado ( $\hat{\Sigma}_0$ ) y el valor de  $\chi^2_{\text{Null}}$  ( $\hat{\Sigma}_{\text{Null}}$ ), siendo el modelo evaluado un modelo multidimensional. El segundo, es que estos índices siguen únicamente una estrategia comparativa, dejando la estrategia inferencial solamente para el valor

---

<sup>4</sup> Referencias tomadas de Marsh et al. (2005).

$\chi^2$  que produce el modelo evaluado ( $\chi^2_0$ ). Sobre el modelo de independencia, Jöreskog y Sörbom (1993) y Jöreskog (2004), han señalado que es recomendable poner a prueba  $\chi^2_{\text{Null}}$  antes de ajustar un modelo ya que si no es posible rechazar la hipótesis expresada en (8) no tiene sentido modelizar los datos mediante SEM porque las variables observables podrían no estar suficientemente correlacionadas. Por su parte, Mulaik (2009, p. 207) ha tratado también la cuestión de poner a prueba  $\chi^2_{\text{Null}}$ , aunque de una manera más indirecta. Este autor plantea la posibilidad de realizar este test simultáneamente al test que pone a prueba la hipótesis nula de que los parámetros estimados son distintos de cero (prueba  $t$  aplicada a cada valor de  $\hat{\lambda}_{ij}$ ). Sorprendentemente, esta vía de evaluación del modelo (salvo las referencias comentadas) no aparece reflejada ni en la literatura ni en la práctica convencional del AFC, quedando la estrategia inferencial reservada únicamente a la prueba  $\chi^2_0$ .

En el presente trabajo, se ha aplicado esta lógica inferencial sobre el modelo de independencia en combinación con la necesidad de obtener evidencias de consistencia empírica de cada clúster independiente. Frente a la evaluación del modelo multidimensional, y como se argumentó más arriba, se propone realizar la prueba  $\chi^2_{\text{Null}}$  para cada factor VCL evaluado como clúster independiente.

Evaluar cada clúster antes del modelo “global” es una estrategia que también ha sido defendida por Jöreskog y Sörbom (1993, p. 128), aunque esta estrategia tampoco aparece reflejada en la práctica convencional del AFC ni en las recomendaciones aportadas por la RPP. Jöreskog y Sörbom desarrollaron y recomendaron una estrategia general de análisis que va más allá de la práctica convencional del AFC, especialmente en su segunda fase, que es la más relevante desde el punto de vista del presente trabajo. Estos autores recomiendan como primer paso especificar el modelo inicial en base a la teoría o, al menos, fijar hipótesis o ideas tentativas

sobre cuál puede ser el modelo a evaluar. *En segundo lugar, estimar el modelo de medida para cada constructo de forma individual, después para cada par de constructos, y por último estimar el modelo completo.* En tercer lugar, evaluar el ajuste de cada modelo estimado en el paso anterior, prestando especial atención al valor de  $\chi^2$ , errores estándar, niveles críticos de  $t$ , residuos estandarizados y a los índices de modificación. En cuarto lugar, lo deseable sería poner a prueba el modelo final en nuevas muestras (y los modelos alternativos que hayan podido surgir en caso de re-especificación)<sup>5</sup>. Si no se dispone de nuevas muestras pero la muestra inicial es elevada, se puede considerar realizar un proceso de validación cruzada segmentando en dos submuestras. También se puede utilizar el índice *Expected Cross Validation* o ECVI para evaluar cada modelo. ECVI es una medida de distancia entre la matriz de covarianzas ajustada en la muestra de calibración ( $\hat{\Sigma}$ ) y la matriz observada de la muestra de validación ( $S$ ). El uso de ECVI también ha sido recomendado en algunos de los trabajos revisados en la RPP. Por ejemplo, MacCallum y Austin (2000) proponen la utilidad de este índice cuando se comparan modelos alternativos con tamaños muestrales reducidos; Shah y Goldstein (2006) recomiendan su uso dada la dificultad habitual que existe en la investigación aplicada para conseguir múltiples muestras. En el contexto del AFE, Fabrigar et al. (1999) también resaltan aspectos positivos de utilizar este índice.

En ausencia de otros errores de especificación, cuando las variables observables no presentan interrelación, el clúster evaluado tendrá una varianza común nula, aproximándose al modelo de independencia poblacional ( $\hat{\Sigma}_0 = \hat{\Sigma}_{\text{Null}} \sim \Sigma_{\text{Null}}$ ). Asumiendo relaciones positivas, a medida que aumenta el nivel de interrelación entre las variables observables, el modelo

---

<sup>5</sup> Por su parte, Mulaik (2009, pp. 201-210) plantea la realización simultánea de la prueba  $\chi^2_{\text{Null}}$  y de la prueba  $t$  sobre  $\hat{\lambda}_{ij}$  en las fases finales de la estrategia de análisis propuesta por este autor, que denominó “procedimiento en cuatro pasos” (*the four step procedure*).



evaluado empieza a diferenciarse del modelo de independencia ( $\hat{\Sigma}_0 \neq \Sigma_{Null}$ ), y la forma en la que podemos poner a prueba hasta qué punto existe distancia entre un modelo y otro es mediante el test  $\chi^2_{Null}$ , bajo la hipótesis nula  $\hat{\Sigma}_0 = \Sigma_{Null}$ . Tras aplicar este test, el clúster independiente podría ser eliminado del modelo por falta de varianza común ( $H_0$ ), o podría decidirse mantenerlo ( $H_1$ , siempre y cuando el investigador considere que tiene la suficiente relevancia teórica y mejore la representación del constructo). No obstante, en caso de no poder rechazar la  $H_0$  del modelo de independencia, antes de rechazar la “existencia” del clúster se deben valorar las condiciones de aplicación para valorar si AFC tiene la suficiente sensibilidad para detectar el factor poblacional. Aplicar normas arbitrarias sobre las características psicométricas o los valores de  $\hat{\lambda}_{ij}$  llevaría probablemente a su exclusión antes de poner a prueba el valor de  $\chi^2_{Null}$  y, como hemos argumentado anteriormente, esta lógica atenta contra la propia naturaleza causal-hipotética de las variables latentes.

En resumen, se propone la siguiente estrategia de evaluación previa o pre-evaluación como herramienta para la toma de decisiones en contextos aplicados ante la presencia de factores VCL que son relevantes desde un punto de vista teórico:

1. Aislar el factor VCL del resto de elementos del modelo (posible influencia de otras variables observables, otros factores, etc.) mediante especificación unifactorial, antes de evaluar el modelo multidimensional. Estimar los parámetros del factor mediante la aplicación de AFC sobre este modelo, lo que permite eliminar la influencia de diferentes fuentes de variación que pueden cambiar los valores de  $\hat{\lambda}_{ij}$  que se deben exclusivamente a la influencia del factor.
2. Evaluar la factorabilidad o grado de adecuación muestral de la matriz aislada. En el marco tradicional del AFE este tipo de evaluación se realiza mediante la aplicación de dos métodos clásicos: el indicador de factorabilidad Kaiser-Meyer-

Oblim o KMO y la prueba de esfericidad de Bartlett. Desde la perspectiva confirmatoria, utilizar el test  $\chi^2_{\text{Null}}$  como medida de factorabilidad, bajo la  $H_0$  de que no existe relación entre las variables observables.

3. Utilizar la aparición de soluciones no convergentes o la presencia de casos Heywood como un primer indicador de la calidad o factorabilidad del modelo (Gagné y Hancock, 2006). En este sentido, ante estimaciones no deseadas de este tipo, puede ser de interés revisar la matriz aislada y aplicar alguna de las recomendaciones sobre cómo paliar la presencia de matrices definidas como no positivas (Wothke, 1993).
4. Si la  $H_0$  del modelo de independencia no puede rechazarse, el investigador puede valorar la eliminación del factor VCL del marco conceptual o revisar la propia teoría. Otra opción sería que el investigador desechara AFC en favor de alguna otra técnica de análisis menos exigente (por ejemplo, análisis clúster o escalamiento multidimensional), revisando a su vez el alcance y los objetivos de su estudio. Si la teoría subyacente es fuerte, bien sustentada en investigaciones previas, lo más recomendable sería cambiar de técnica de análisis. Como un paso intermedio el investigador podría tratar de eliminar cuidadosamente aquellas variables observables con mayores problemas de fiabilidad (una o dos variables, dependiendo de  $n$ ), y repetir el test  $\chi^2_{\text{Null}}$  después de aplicar nuevamente AFC con el conjunto reducido de variables observables.
5. Si se rechaza estadísticamente la  $H_0$  del modelo de independencia, el investigador tiene cierta evidencia empírica de la existencia de un factor común que subyace al conjunto de variables observables analizadas. Una vez alcanzada este tipo de evidencia de consistencia empírica, se pueden utilizar otras fuentes relacionadas

con la precisión de la estimación en la muestra objeto de estudio. Como se indicó más arriba, el uso de los índices descriptivos de ajuste más comunes no resulta apropiado. Recomendamos utilizar ECVI como índice de aproximación a los parámetros poblacionales (Jöreskog y Sörbom, 1993).

6. Independientemente de si la  $H_0$  del modelo de independencia resulta rechazada o no, una cuestión importante a considerar es el reporte de los valores de  $\chi^2_{Null}$ , grados de libertad y nivel crítico obtenidos tras aplicar AFC sobre el factor aislado. Informar de estos valores permitirán a otros investigadores valorar más objetivamente la especificación y evaluación del constructo hipotético subyacente al factor bajo ciertas condiciones de aplicación. Además, también sería recomendable informar siempre del valor de  $R^2$ , de alguna medida de la fiabilidad del factor (por ejemplo, el coeficiente omega: Gagné y Hancock, 2006; McDonald, 1999), y el valor de ECVI. De esta manera, los investigadores podrían comparar el grado de consistencia empírica de este tipo de factores en diferentes estudios y en comparación con otros constructos hipotéticos alternativos.

# CAPÍTULO 2

Diseño de la investigación: estudio de simulación Monte Carlo

## CAPÍTULO 2: Diseño de la investigación: estudio de simulación Monte Carlo

Respecto a la metodología utilizada, se ha realizado un estudio de simulación Monte Carlo (Boomsma, 2013; Skrondal, 2000), a partir de distintas estructuras factoriales, todas ellas unifactoriales. Para el estudio sistemático de la utilidad de la prueba  $\chi^2_{\text{Null}}$  se han tenido en cuenta variaciones en el número de variables observables ( $n$ ) y en el tamaño de la muestra ( $N$ ), en base a lo que indica la revisión de la prácticas de publicación y de los estudios de recuperación citados en el apartado 1.3. Se parte de la simulación de datos continuos y de la estimación mediante *Maximum Likelihood* – ML y *Unweighted Least Squares* – ULS (Ximénez, 2006, 2007, 2009). Además, la evaluación del objeto de estudio se ha extendido a situaciones más realistas, a partir de la simulación de datos ordinales con 5 categorías y sobre datos dicotómicos, con distintos tipos de distribución (condiciones de simetría, asimetría y uniformidad). En total, se han simulado 496 condiciones experimentales, con 1.000 réplicas muestrales por condición. Se evalúan estructuras unifactoriales con el fin de identificar la posible utilidad del modelo de independencia, sin realizar análisis en fases posteriores sobre modelos completos o multidimensionales. Dar continuidad a este proceso de análisis excede los objetivos del presente trabajo. Ante la posibilidad de decidir si se especifican o no factores VCL dentro de un determinado modelo multidimensional (si no se han utilizado cortes arbitrarios sobre las características psicométricas y/o los valores de  $\hat{\lambda}_{ij}$  durante el proceso de selección), nuestra hipótesis principal es que existirá un número relativamente elevado de factores en los que  $\hat{\Sigma}_0 \sim \Sigma_{\text{Null}}$ , siendo  $\hat{\Sigma}_0$  el factor o clúster evaluado.

## 2.1. Modelos y condiciones simuladas

Las estructuras unifactoriales utilizadas en el presente trabajo se han simulado con términos error ( $\delta_{ij}$ ) no correlacionados, por lo que en ausencia de otras variables latentes queda garantizada su unidimensionalidad. En esta situación, el cálculo de los índices descriptivos de ajuste y del resto de variables dependientes (que se describen más adelante), se ha realizado controlando el tipo de error de especificación presente en los modelos (grado de unicidad), tanto en condiciones de homogeneidad como de heterogeneidad (Gagné y Hancock, 2006; Velicer y Fava, 1998; De Winter et al., 2009). La estrategia de modelización y de análisis que se ha seguido se puede caracterizar a partir de los siguientes elementos y procesos:

1. En primer lugar, se parte del análisis de datos en condiciones ideales (datos continuos con distribución normal). Para comparar los resultados que se obtienen a partir de la aplicación de distintos estimadores sobre este tipo de datos, se calculó la matriz de correlaciones de cada solución ( $\mathbf{S}_r$ ) sobre la que se aplicó el método *Unweighted Least Squares* (ULS), y la matriz de varianzas-covarianzas ( $\mathbf{S}_{cov}$ ) sobre la que se aplicó el método *Maximum Likelihood* (ML). Esta distinción en el cálculo de las matrices que se analizan al ajustar los distintos modelos evaluados se debe a que ULS no es un método adecuado cuando se analiza  $\mathbf{S}_{cov}$  ya que el tamaño de los residuos dependerá de la escala de medida de las variables observables. Para utilizar este estimador es recomendable utilizar  $\mathbf{S}_r$  (Abad, Olea, Ponsoda, y García, 2011; Jöreskog, Sörbom, y Du Toit, 2001). En la Figura 2 se muestra esquemáticamente el tipo de modelos simulados.

2. Una vez obtenidos los resultados de la evaluación con este tipo de datos, se han replicado los análisis para el caso de datos ordinales (5 categorías) y para el caso de datos dicotómicos, con el fin de evaluar situaciones más realistas, más próximas a la práctica habitual del AFC en contextos aplicados. La discretización de los datos se elaboró a partir del establecimiento de puntos de corte sobre los datos continuos simulados inicialmente. Mediante este proceso se evita introducir fuentes adicionales de variación debidas a la aleatorización de las variables observables. La estimación de todos estos modelos se ha realizado sobre la matriz de correlaciones policóricas o  $\mathbf{S}_p$  (tetracóricas para datos dicotómicos, o  $\mathbf{S}_t$ ), obtenidas a partir de los datos discretizados. Cuando se trabaja con este tipo de datos, la utilización de los estimadores para datos continuos no es correcta, por lo que se deben utilizar otros estimadores (Yang-Wallentin, Jöreskog, y Lou, 2010). Para realizar el ajuste de los modelos a estos datos, y siguiendo la terminología LISREL, se ha utilizado *Robust Unweighted Least Squares* (RULS), *Robust Diagonal Weighted Least Squares* (RDWLS) y *Robust Maximum Likelihood* (RML). Los métodos de estimación utilizados se detallan en el apartado 2.2.1.
3. Se han diferenciado tres tipos de distribución para cada tipo de variable discretizada (ver Figura 3). Con datos ordinales se han simulado distribuciones utilizadas en estudios previos para evaluar el resultado de la estimación ante situaciones de no normalidad en escalas de respuesta tipo *Likert* (Muthén y Kaplan, 1992). La distribución 1 (5D1) reproduce la situación de normalidad simulada con datos continuos pero aplicada sobre 5 categorías, la distribución 2 (5D2) simula una situación con fuerte asimetría negativa y la distribución 3 (5D3) simula una situación de homogeneidad en la distribución de los valores de las variables observables. La distribución de los datos dicotómicos mantiene una estructura similar: la distribución 1 (2D1) se asemeja a 5D1 y 5D3 ya que refleja una distribución

simétrica (Yang-Wallentin et al., 2010), mientras que la distribución 2 (2D2) es similar a 5D3 al reflejar asimetría negativa. Adicionalmente, se analiza un caso distinto en el que se ha simulado fuerte asimetría positiva (2D3).

Figura 2. Modelos AFC teóricos (poblacionales) utilizados en los estudios de simulación







Figura 3. Número de categorías discretas y tipo de distribución de los datos simulados a partir de los datos continuos originales



4. Para simplificar el extenso trabajo que supone realizar todo el proceso de simulación y ajuste de modelos que se deriva de las condiciones definidas más arriba, se ha procedido de manera secuencial. El primer paso ha sido aplicar la lógica expuesta sobre la pre-evaluación del modelo de independencia a los datos continuos, considerando todas las combinaciones posibles entre condiciones. Este análisis nos ha permitido identificar que la condición  $\lambda_{ij} = 0,2$  resulta problemática, salvo en combinación con otras condiciones a nivel óptimo (elevado número de indicadores y tamaño muestral elevado). Por esta razón, en la evaluación de los datos ordinales y dicotómicos se excluye el análisis de la condición  $\lambda_{ij} = 0,2$ . También se excluye el análisis de las condiciones  $n = 7$  y  $n = 15$ , ya que el valor  $n = 6$  garantiza una adecuada recuperación en buena parte de las condiciones simuladas. Todas estas cuestiones serán tratadas en detalle en el Capítulo 3, si bien resulta conveniente introducir esta nota en el capítulo metodológico con el fin de orientar al lector sobre las características diferenciales de los estudios de simulación realizados. En este sentido, los resultados obtenidos se han dividido en dos estudios: el ESTUDIO 1 que se centra en los resultados obtenidos a partir del análisis de datos continuos, y el ESTUDIO 2, centrado a su vez en el análisis de datos ordinales y dicotómicos, como se comentó en el apartado introductorio de este trabajo.
  
5. Con el fin de obtener un mayor nivel de generalización de nuestros resultados, se realizaron otros estudios de simulación teniendo en cuenta un rango de valores de  $\lambda_{ij}$  para cada factor (o nivel de carga heterogéneo), en lugar de valores fijados con el mismo nivel de carga como los evaluados en los estudios anteriores (Gagné y Hancock, 2006; Velicer y Fava, 1998; De Winter et al., 2009). Para estas simulaciones se mantuvieron las mismas condiciones en cuanto al número de observaciones, pero se utilizaron únicamente las condiciones  $n = 4$  y  $n = 5$ . Para  $n = 4$  se utilizaron las siguientes cargas factoriales:  $\lambda_{1j} = 0,45$ ,  $\lambda_{2j} = 0,35$ ,  $\lambda_{3j} = 0,25$

y  $\lambda_{4j} = 0,15$  (condición  $\lambda_{ij} (0,15-0,45)$ ). Para  $n = 5$  se utilizaron las siguientes cargas factoriales:  $\lambda_{1j} = 0,3$ ,  $\lambda_{2j} = 0,2$ ,  $\lambda_{3j} = 0,1$ ,  $\lambda_{4j} = 0,4$  y  $\lambda_{5j} = 0,5$  (condición  $\lambda_{ij} (0,1-0,5)$ ).

6. El proceso de pre-evaluación de los distintos modelos también se ha realizado en algunas condiciones adicionales con el fin de valorar algunos aspectos de interés en la aplicación de AFC. Gracias a la RPP podemos identificar que la práctica habitual del AFC presenta de manera más o menos frecuente factores compuestos por 3 variables observables ( $n = 3$ ). Si se aísla este conjunto de variables observables, la estructura factorial está exactamente identificada: asumiendo que la varianza del factor  $\xi$  está fijada a 1 (como sucede por defecto al ajustar modelos con LISREL), la matriz de entrada ( $S_{cov}$ ) contiene 3 varianzas y 3 covarianzas conocidas y la matriz estimada ( $\hat{\Sigma}_0$ ) contiene 6 parámetros estimados libremente (Brown, 2015, p. 57). Para ajustar este tipo de modelos no se precisa de método de estimación, puesto que el cálculo de  $\hat{\Sigma}_0$  produce un solo conjunto de parámetros que reproduce perfectamente las correlaciones entre las variables observables. Por esta razón, no resultan aplicables los distintos índices descriptivos de ajuste, ya que  $\hat{\Sigma}_0 = S$ . No obstante, dado que este tipo de factores están presentes en la práctica convencional, se han realizado algunas simulaciones con el fin de valorar el grado en el que se producen problemas de convergencia, y el grado en el que se recuperan los parámetros poblacionales con la suficiente precisión, conocida  $\Sigma_0$ . No se utilizaron datos continuos, se excluyeron los datos con distribución 5D3 y 2D2, y se añadió el análisis de la condición  $\lambda_{ij} = 0,5$ . Se ha utilizado el método de estimación RDWLS para ajustar las matrices de correlaciones policóricas mediante LISREL, pero solamente a efectos de uso del software.

En resumen, los modelos simulados son los siguientes (en Anexos se detalla toda esta información mediante esquemas y cuadros):

- **ESTUDIO 1 (Datos continuos):**

---

⇒  $\lambda_{ij} = 0,2, 0,3 \text{ y } 0,4$ .

⇒  $N = 200, 300, 400 \text{ y } 500$  observaciones.

⇒  $n = 4, 5, 6, 7 \text{ y } 15$  variables observables.

⇒ Método estimación ( $E$ ): ML y ULS.

$3(\lambda_{ij}) \times 4(N) \times 5(n) \times 2(E) = 120$  condiciones experimentales.

---

⇒  $n = 4 \text{ y } 5$ .

⇒ Nivel de carga heterogéneo:  $\lambda_{ij} (0,15-0,45)$  y  $\lambda_{ij} (0,1-0,5)$ .

⇒  $N = 200, 300, 400 \text{ y } 500$  observaciones.

⇒ Método estimación ( $E$ ): ML.

$1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 8$  condiciones experimentales.

---

- **ESTUDIO 2:**

- **Datos ordinales (5 categorías):**

---

⇒  $\lambda_{ij} = 0,3$ .

⇒ Distribución ( $D$ ) = 5D1, 5D2 y 5D3.

⇒  $N = 200, 300, 400 \text{ y } 500$  observaciones.

⇒  $n = 4, 5 \text{ y } 6$  variables observables.

⇒ Método estimación ( $E$ ): RDWLS, RML y RULS.

$3(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 108$  condiciones experimentales.

---

⇒  $\lambda_{ij} = 0,4$ .

⇒ Distribución ( $D$ ) = 5D2.

⇒  $N = 200, 300, 400 \text{ y } 500$  observaciones.

⇒  $n = 4, 5 \text{ y } 6$  variables observables.

⇒ Método estimación ( $E$ ): RDWLS, RML y RULS.

$1(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 36$  condiciones experimentales.

---

⇒  $n = 4 \text{ y } 5$ .

⇒ Nivel de carga heterogéneo:  $\lambda_{ij} (0,15-0,45)$  y  $\lambda_{ij} (0,1-0,5)$ .

⇒ Distribución ( $D$ ) = 5D1 y 5D2.

⇒  $N = 200, 300, 400 \text{ y } 500$  observaciones.

⇒ Método estimación ( $E$ ): RDWLS.

$2(D) \times 1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 16$  condiciones experimentales.

---

---

$\Rightarrow n = 3$ .  
 $\Rightarrow \lambda_{ij} = 0,3, 0,4 \text{ y } 0,5$ .  
 $\Rightarrow$  Distribución  $(D) = 5D1 \text{ y } 5D2$ .  
 $\Rightarrow N = 200, 300, 400 \text{ y } 500$  observaciones.  
 $\Rightarrow$  Método estimación  $(E)$ : RDWLS (*uso del software*).  
 $2(D) \times 3(\lambda_{ij}) \times 4(N) \times 1(n) \times 1(E) = 24$  condiciones experimentales.

---

▪ **Datos dicotómicos:**

---

$\Rightarrow \lambda_{ij} = 0,3$ .  
 $\Rightarrow$  Distribución  $(D) = 2D1, 2D2 \text{ y } 2D3$ .  
 $\Rightarrow$  Resto de condiciones igual que con 5 categorías.  
 $3(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 108$  condiciones experimentales.

---

$\Rightarrow \lambda_{ij} = 0,4$ .  
 $\Rightarrow$  Distribución  $(D) = 2D3$ .  
 $\Rightarrow$  Resto de condiciones igual que con 5 categorías.  
 $1(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 36$  condiciones experimentales.

---

$\Rightarrow n = 4 \text{ y } 5$ .  
 $\Rightarrow$  Nivel de carga heterogéneo:  $\lambda_{ij} (0,15-0,45)$  y  $\lambda_{ij} (0,1-0,5)$ .  
 $\Rightarrow$  Distribución  $(D) = 2D1 \text{ y } 2D3$ .  
 $\Rightarrow$  Resto de condiciones igual que con 5 categorías.  
 $2(D) \times 1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 16$  condiciones experimentales.

---

$\Rightarrow n = 3$ .  
 $\Rightarrow$  Distribución  $(D) = 2D1 \text{ y } 2D3$ .  
 $\Rightarrow$  Resto de condiciones igual que con 5 categorías.  
 $2(D) \times 3(\lambda_{ij}) \times 4(N) \times 1(n) \times 1(E) = 24$  condiciones experimentales.

---

En total, se han simulado 496 condiciones experimentales: 128 (25,8%) con datos continuos, 184 con datos ordinales (5 categorías), y 184 con datos dicotómicos (74,2%). Por método de estimación, la distribución de condiciones es de un 13,7% para ML, 12,1% para ULS, 35,5% para RDWLS, 19,3% para RML, y un 19,3% para RULS.

Otra forma de clasificar estos estudios de simulación es la siguiente: 456 condiciones experimentales con  $\lambda_{ij}$  fijos en un mismo nivel de carga (8,8% con  $\lambda_{ij} = 0,2$ , 59,7% con  $\lambda_{ij} =$

0,3 28,1% con  $\lambda_{ij} = 0,4$ , y 3,5% con  $\lambda_{ij} = 0,5$ ), y 40 condiciones con niveles heterogéneos de carga factorial. La distribución de las condiciones en función del número de variables observables es la siguiente:  $n = 3$  (9,7%),  $n = 4$  (28,2%),  $n = 5$  (28,2%),  $n = 6$  (24,2%),  $n = 7$  (4,8%), y  $n = 15$  (4,8%).

## 2.2. Procedimiento de simulación y estimación: PRELIS 2.0 y LISREL 8.8

Para cada condición experimental definida se simularon 1.000 réplicas muestrales mediante el programa PRELIS 2 (Jöreskog y Sörbom, 1996b), utilizando siempre la misma semilla de aleatorización. Se generaron inicialmente los datos continuos con distribución normal, a partir de los cuales se calcularon las matrices  $\mathbf{S}_r$  y  $\mathbf{S}_{cov}$ . Los modelos AFC se ajustaron sobre estas matrices mediante el programa LISREL 8.8 (Jöreskog y Sörbom, 1996a), utilizando como método de estimación ULS sobre  $\mathbf{S}_r$  y ML sobre  $\mathbf{S}_{cov}$ . La estimación de los modelos se realizó manteniendo el criterio de convergencia por defecto que utiliza este programa (hasta 250 iteraciones), e identificando aquellas soluciones que no resultaban convergentes y/o que presentaban casos *Heywood* (en adelante, se ha denominado IM a este tipo de soluciones no válidas o impropias). Para una revisión del procedimiento de simulación con datos continuos se pueden consultar los trabajos de Ximénez (2006, 2007).

A partir de los datos anteriores, como se comentó más arriba, se discretizaron las variables observables en 5 y 2 categorías y se obtuvieron las distintas matrices de correlaciones policóricas ( $\mathbf{S}_p$ ) y tetracóricas ( $\mathbf{S}_t$ ). Para la obtención de estas matrices fue necesario realizar procedimientos en los programas PRELIS 2 y LISREL 8.8 diferentes a los desarrollados con datos continuos, siguiendo las indicaciones de Yang-Wallentin et al. (2010, en apéndice). En Anexos se muestran varios ejemplos de sintaxis elaborados con estos programas que muestran estas diferencias de procedimiento. Lo primero que hay que destacar es que para obtener las matrices  $\mathbf{S}_p$  y  $\mathbf{S}_t$  se debe trabajar con archivos de datos en extensión \*.RAW. Además, para realizar estimaciones robustas a partir de estas matrices se debe obtener también la matriz asintótica de varianzas-covarianzas (archivo \*.ACP). Todos estos cálculos se elaboran con PRELIS.

Una vez obtenidas las distintas matrices, se procedió a realizar la estimación mediante LISREL. Nótese que en la sintaxis empleada con datos ordinales y dicotómicos el método de estimación utiliza tanto la matriz  $S_p$  ( $S_t$  en el caso de datos dicotómicos) como el archivo \*.ACP. Mediante el comando ME puede establecerse el tipo de estimador a utilizar para ajustar los datos (ME = ML/ULS para datos continuos, y ME = ML/ULS/DWLS para datos ordinales y dicotómicos; cuando se trabaja siguiendo el procedimiento descrito en los ejemplos ilustrativos de los Anexos, estos tres últimos estimadores se consideran métodos robustos). Es importante señalar que los valores de  $\chi^2$  varían en el *output* de LISREL en función del tipo de estimación ejecutado, existiendo hasta cuatro valores diferentes (C1, C2, C3 y C4: Jöreskog, 2004); en el presente trabajo se ha seleccionado el valor correspondiente en función del estimador. El proceso de estimación con LISREL permite generar distintos archivos en los que se almacena toda la información relevante para cada solución o réplica muestral analizada. Estos archivos son los siguientes: \*.PV en el que se almacenan los valores de los parámetros estimados, \*.SV en el que se almacenan los errores de estimación, y \*.GF en el que se almacenan todos los índices descriptivos de ajuste y otros resultados de interés (ajuste comparativo, etc.). Todo este procedimiento viene descrito en el manual de PRELIS 2 (Jöreskog y Sörbom, 1996b), en el Apéndice C sobre estudios Monte Carlo.

### 2.2.1. Métodos de estimación

La lógica de la estimación de parámetros se articula, fundamentalmente, en torno a un proceso de búsqueda de aquel conjunto de parámetros que minimice las diferencias entre los elementos de la matriz *observada* ( $S$ ) y los elementos de la matriz reproducida o *estimada* ( $\hat{\Sigma}$ ) mediante AF. En la práctica, el ajuste perfecto no resulta plausible ya que en Psicología la



medición de variables introduce alguna cantidad de error. Por lo tanto, la situación de partida es aquella en la que  $\hat{\Sigma} \neq S$ , existiendo diferencias o residuos entre los parámetros reproducidos por el modelo y su valor observado a nivel muestral. Estas diferencias se utilizan para expresar la cantidad de discrepancia entre ambas matrices, aplicando una función lineal que se denomina *función de discrepancia* entre  $S$  y  $\hat{\Sigma}$ , o  $F(S; \hat{\Sigma})$ , y su expresión matemática varía según sea el método de estimación empleado. Esto es, la forma concreta que adopta esta función, según los desarrollos de distintos autores, es la que conforma los distintos métodos de estimación utilizados.

Los residuos o diferencias resultantes al comparar  $S$  y  $\hat{\Sigma}$  se pueden formalizar en un vector  $\mathbf{d} = \{d_1, d_2, \dots, d_i\}$ . Con los residuos obtenidos ( $\mathbf{d}$ ) se calcula el valor correspondiente de la función de discrepancia ( $F$ ) en cada paso del proceso, seleccionando finalmente aquel conjunto de residuos que produzca el valor más próximo a cero, esto es, que reproduzca más fielmente la matriz  $S$  original. Mediante dicho proceso iterativo, cada método pretende alcanzar una solución final que minimice el valor de  $F$ . El proceso consta de tres pasos: (1) selección de valores iniciales, (2) reglas que establecen cuándo cambiar al paso siguiente, y (3) reglas que establecen cuándo finalizar el proceso iterativo (la formalización matemática de este proceso puede consultarse en Bollen, 1989; apéndice 4C). Cuando se alcanza una solución final, entonces decimos que la solución o modelo es convergente.

A continuación se describen las funciones de discrepancia que se obtienen al estimar un determinado modelo  $\hat{\Sigma}_0$  de dos de los métodos más frecuentes en la literatura sobre AF para datos continuos, y que se diferencian en la forma en la que tratan matemáticamente el vector  $\mathbf{d}$ : Máxima Verosimilitud (*Maximum Likelihood* - ML) y Mínimos Cuadrados no Ponderados (*Unweighted Least Squares* - ULS). Utilizando el vector  $\mathbf{d}$ , las expresiones matemáticas de estos dos métodos son las siguientes:  $F_{ML} = \mathbf{d}'\mathbf{W}\mathbf{d}$  y  $F_{ULS} = \mathbf{d}'\mathbf{d}$ . El caso más sencillo es el de

ULS, en donde  $F$  obtiene su valor calculando la suma de cuadrados de los residuos. Matricialmente, la matriz de ponderación  $\mathbf{W}$  se sustituye por una matriz identidad ( $\mathbf{I}$ ), simplificando la función de discrepancia expresada para ML y obteniendo estimaciones consistentes con tamaños muestrales suficientes. Como se comentó,  $F_{\text{ULS}}$  no es recomendable cuando se utilizan matrices de varianzas-covarianzas; su uso está recomendado cuando se analizan matrices de correlaciones, con soluciones estandarizadas o totalmente estandarizadas, ya que ULS no asume ningún tipo de distribución.

Utilizando matrices  $\mathbf{W}$  más complejas se pueden obtener *estimaciones asintóticamente eficientes*, esto es, estimadores que convergen más rápidamente sobre los valores de los parámetros poblacionales a medida que aumenta el tamaño muestral (estimaciones en las que la varianza del parámetro estimado converge más rápidamente hacia cero). El método ML es más eficiente que otros métodos de estimación de parámetros. Asumiendo que la distribución de las variables observables es normal multivariante, el método ML sustituye en  $F_{\text{ML}}$  la matriz  $\mathbf{W}$  por la matriz  $\mathbf{\Gamma}^{-1}$  (Muthén, 1993). La matriz  $\mathbf{\Gamma}$  es la denominada *matriz de varianzas-covarianzas asintótica*, y se refiere a la variabilidad que tendrían los elementos de la matriz  $\mathbf{S}$  a través de distintas muestras, lo que permite obtener (tras varios cálculos) una estimación asintótica para cada uno de estos elementos a partir de sus valores esperados. Al invertir  $\mathbf{\Gamma}$ , la ponderación de  $F_{\text{ML}}$  asigna valores más pequeños al vector  $\mathbf{d}$  cuanto mayores son los elementos correspondientes en  $\mathbf{S}$ , puesto que en estas condiciones se asume que su variabilidad *entre-muestras* será también mayor. De esta manera, se relativizan los residuos potencialmente mayores permitiendo realizar la estimación más eficientemente.

En situaciones en las que las variables observables a analizar son de tipo ordinal o categórico, diversos autores han desarrollado métodos de estimación que suponen una generalización de los métodos utilizados con variables continuas (Jöreskog, 1990, 1994;

Muthén, 1978, 1984; Yang-Wallentin et al., 2010). En los AF aplicados sobre datos discretos se asume que para cada variable observable ( $x$ ), subyace una variable de respuesta latente ( $x^*$ ) que es continua. La relación entre la variable observable y su continuo de respuesta latente se establece definiendo la existencia teórica de puntos de corte o *umbrales* en el continuo latente:

$$x_i = q \quad \text{si} \quad \tau_{i,q} < x_i^* < \tau_{i,q+1} \quad (11)$$

En donde  $q$  es la categoría de respuesta de la variable observable  $i$ , y los umbrales ( $\tau$ ) definen los márgenes en el continuo latente que permiten establecer correspondencias entre los valores de  $x^*$  y los valores de  $x$ <sup>6</sup>. Desde esta perspectiva se asume que cuando una determinada persona selecciona una categoría de respuesta, el valor de su respuesta latente  $x^*$  se encontrará dentro de un rango de valores establecido por el umbral inmediatamente inferior asociado al valor observado en  $x$  y por el umbral inmediatamente superior.

El proceso de estimación se desarrolla en tres etapas sucesivas: (1) se estiman los umbrales para cada variable observable  $x$ , (2) se estiman las correlaciones policóricas (o tetracóricas) para cada par de variables utilizando los umbrales iniciales, y (3) se estiman los parámetros que minimizan  $F$  solo que en este caso los residuos ( $\mathbf{d}$ ) se calculan en base a la matriz de correlaciones estimada en el paso (2). El proceso de minimización de la función de discrepancia sigue la misma lógica expuesta más arriba para datos continuos, dando lugar a los distintos métodos de estimación para modelos ordinales y categóricos dependiendo del tipo de matriz de pesos  $\mathbf{W}$  que se utilice. En este trabajo se han utilizado los estimadores RDWLS,

---

<sup>6</sup> En el caso de variables observables ordinales se debe cumplir adicionalmente la siguiente condición:  $-\infty = \tau_0 < \tau_1 < \tau_2 \dots < \tau_{m-1} < \tau_m = \infty$ , en donde  $m$  es el número de categorías ordenadas de las variables  $x$ .

RML y RULS (el desarrollo técnico de estos estimadores se puede consultar en Yang-Wallentin et al., 2010, pp. 396-398).

### 2.2.2. Selección de variables dependientes

Las variables dependientes definidas en el presente trabajo se han utilizado con el fin de valorar la sensibilidad para discriminar entre aquellas soluciones en las que se rechaza la  $H_0$  del modelo de independencia, de aquellas otras soluciones en las que dicha hipótesis no puede ser rechazada estadísticamente. Por simplicidad, al primer conjunto de soluciones las hemos denominado soluciones tipo 1 o T1 (esto es, clústers que muestran evidencias de consistencia empírica), y al segundo conjunto soluciones tipo 2 o T2 (soluciones sin consistencia empírica).

La cantidad de información que puede ser analizada cuando se ajustan modelos AFC es bastante grande. Para facilitar su presentación, en este trabajo se han diferenciado cuatro grandes bloques de variables: uno compuesto por aquellas variables que identifican problemas graves de estimación (problemas de convergencia y/o presencia de casos *Heywood*, que denominaremos soluciones IM), otro compuesto por variables que permiten evaluar el ajuste teórico de los modelos estimados, otro compuesto por los denominados índices descriptivos de ajuste, y el último compuesto por índices que se utilizan con menor frecuencia según la revisión de la práctica de publicación o RPP y que planteamos aquí como alternativa a los anteriores para la pre-evaluación de factores VCL.

### *Soluciones impropias (IM)*

Para identificar soluciones no convergentes se ha utilizado la información que genera LISREL en cada archivo \*.PV, \*.SV y \*.GF, al codificar dichas soluciones con el valor 1. Además, a partir de los archivos \*.PV se han identificado valores aberrantes o casos *Heywood*, como términos error  $< 0$ , o cargas factoriales fuera del rango  $\pm 1$ . En conjunto, si una solución presenta alguna de estas dos características (falta de convergencia o presencia de casos *Heywood*), se considera una *solución IM*, una solución que no debe ser evaluada en términos de recuperación de parámetros. Esta información será tratada al principio de cada uno de los dos estudios expuestos en el Capítulo 3 de resultados, sirviendo para una primera valoración de la sensibilidad del AFC en ciertas condiciones y para un primer filtrado de los modelos que serán evaluados en los apartados siguientes (Gagné y Hancock, 2006; Ximénez, 2006, 2007).

### *Evaluación del ajuste teórico*

Para este tipo de evaluación se ha calculado la discrepancia entre el valor poblacional de las cargas factoriales simulado ( $\lambda_{ij}$ ) y su valor estimado mediante AFC ( $\hat{\lambda}_{ij}$ ). Esta discrepancia permite evaluar la estabilidad, precisión o calidad de la recuperación de parámetros en los distintos modelos propuestos en términos de ajuste teórico (Olsson et al., 2000). En nuestro caso, hemos calculado el coeficiente de congruencia ( $C_j$ ) propuesto por Tucker (1951), y Tucker y Lewis (1973), el cual ha sido utilizado en estudios previos (Briggs y MacCallum, 2003; MacCallum et al., 1999; Ximénez, 2006, 2007; De Winter et al., 2009). Este índice (ver expresión (12)) calcula la discrepancia entre la carga poblacional ( $\lambda_{ij}$ ) y la estimada ( $\hat{\lambda}_{ij}$ ), para cada variable observable  $i$  del factor  $j$ , en donde  $n$  es el número de variables observables. El coeficiente de congruencia oscila entre  $\pm 1$  y se interpreta en el mismo sentido que la correlación

de Pearson, indicando una recuperación excelente con valores por encima de 0,98, aceptable con valores entre 0,92 – 0,98, en el límite de lo aceptable con valores entre 0,82 - 0,92, y una recuperación claramente inestable con valores  $< 0,82$  (MacCallum et al., 1999). A nivel global, para la evaluación del ajuste teórico de las soluciones generadas en el presente trabajo se ha tomado el valor  $\geq 0,92$  como indicativo de ajuste.

$$C_j = \frac{\sum_{i=1}^n \lambda_{ij} \hat{\lambda}_{ij}}{\sqrt{(\sum_{i=1}^n \lambda_{ij}^2)(\sum_{j=1}^p \hat{\lambda}_{ij}^2)}} \quad (12)$$

También se ha utilizado el índice *Root Mean Square Deviation* ( $RMSD_j$ ), y los índices *Average Relative Bias* ( $ARB_j$ ) y *Average Root Mean Square Error* ( $AMSE_j$ ), cuyas expresiones formales se muestran en (13), (14) y (15). El índice  $RMSD_j$ , definido por Levine (1977), oscila entre 0 y 2, aunque a veces puede superar el valor 2 cuando se aplica sobre soluciones con una recuperación excesivamente imprecisa (Ximénez, 2006, 2007). Cuanto menor sea su valor, mayor será el grado de ajuste teórico, indicando una recuperación de parámetros satisfactoria cuando obtiene valores por debajo de 0,20.  $ARB_j$  y  $AMSE_j$  han sido utilizados por Yang-Wallentin et al. (2010) para la evaluación del ajuste teórico de modelos ordinales. Basándose en estudios de simulación previos (Curran, West, y Finch, 1996; Kaplan, 1988, 1989), estos autores consideran un desajuste como trivial cuando se obtienen valores por debajo de 0,05, un desajuste moderado con valores entre 0,05 y 0,10, y un desajuste substancial con valores superiores a 0,10.

$$RMSD_j = \sqrt{\sum_{i=1}^n \frac{(\lambda_{ij} - \hat{\lambda}_{ij})^2}{n}} \quad (13)$$

$$ARB_j = \sum_{i=1}^n \frac{(\hat{\lambda}_{ij} - \lambda_{ij})}{\lambda_{ij}} \quad (14)$$

$$AMSE_j = \sqrt{\sum_{i=1}^n \left( \frac{(\hat{\lambda}_{ij} - \lambda_{ij})}{\lambda_{ij}} \right)^2} \quad (15)$$

Nótese que todas estas expresiones se refieren a la magnitud de la discrepancia para un factor determinado, compuesto por  $n$  variables observables. En el Capítulo 3 de resultados los valores informados corresponden a valores promedio en el conjunto de réplicas válidas por condición experimental. Se omite por simplicidad el símbolo del promedio en todas estas expresiones que aparecen en los cuadros y tablas resumen (por ejemplo,  $\bar{C}_j$ ).

#### *Evaluación del ajuste empírico (índices descriptivos de ajuste)*

Aunque aparezca indicado en tercer lugar, el primer valor a considerar en todo el conjunto de estudios de simulación realizados es el de  $\chi^2_{\text{Null}}$ , junto al de sus grados de libertad ( $gl_{\text{Null}}$ ) y su nivel crítico ( $p_{\text{Null-value}}$ ). La primera diferenciación que se ha hecho de los modelos estimados a nivel de resultados ha sido, como se ha comentado, la distinción entre soluciones T1 ( $H_1$  modelo independencia) y T2 ( $H_0$  modelo independencia). Siguiendo la clasificación de índices descriptivos de ajuste seguida en este trabajo, además de la prueba inferencial  $\chi^2_{\text{Null}}$  estarían también los índices y pruebas más utilizadas en la evaluación de la bondad de ajuste de modelos AFC: prueba  $\chi^2$  sobre el modelo evaluado ( $\chi^2_0$ ), RMSEA, SRMR, NNFI y CFI. Estas medidas de ajuste han sido descritas extensamente en la literatura (por ejemplo, Bollen, 1989; Hu y Bentler, 1999; Jöreskog, 1993; Marsh et al., 1988; Marsh et al., 2005; Mulaik, 2009), por lo que no se incide en su elaboración y cálculo en este trabajo.

*Evaluación del ajuste empírico (índices alternativos)*

Jöreskog y Sörbom (1993, p. 124) han propuesto utilizar como medidas de información del ajuste de modelos los índices *Akaike Information Criterion* (AIC), *Consistent AIC* (CAIC) y *Expected Cross-Validation Index* (ECVI) en relación a estos mismos valores aplicados sobre el modelo de independencia. Esta aproximación trata de hacer frente al problema implícito de la prueba  $\chi^2$  cuando se comparan modelos alternativos, ya que el valor de este estadístico decrece a medida que aumenta el número de parámetros en el modelo evaluado (lo que ocurre con cierta frecuencia tras el proceso de re-especificación). Estas medidas de información se han propuesto como una alternativa a las pruebas de significación estadística en la comparación de modelos (Marsh et al., 2005). En los tres casos se interpretan valores más pequeños como indicativos de mayor adecuación o ajuste.

El programa LISREL ofrece tres valores para cada uno de estos índices: uno para el modelo de independencia, otro para el modelo evaluado y otro para el modelo saturado. Siguiendo los objetivos propuestos en este trabajo, se ha explorado la sensibilidad de estos índices a la hora de discriminar soluciones T1 y T2, utilizando los valores que generan los dos primeros modelos, el de independencia y el evaluado. Para simplificar el elevado volumen de información generado se han utilizado ratios que consisten en dividir el valor obtenido para el modelo de independencia por el valor obtenido para el modelo evaluado (ECVI<sub>r</sub>, AIC<sub>r</sub> y CAIC<sub>r</sub>). De esta forma, valores mayores que 1 indican que el valor más alto es el del modelo de independencia; en consecuencia, el modelo evaluado es el que ajusta mejor, diferenciándose así de una solución T2. Al contrario, valores inferiores a 1 indican un mejor ajuste del modelo de independencia.



El programa LISREL ofrece por defecto los valores de estos tres índices a partir de las siguientes expresiones (Schermetleh-Engel et al., 2003), siendo  $t$  el número de parámetros a estimar y  $N$  el número de observaciones:

$$AIC = \chi^2 + 2t \quad (16)$$

$$CAIC = \chi^2 + (1 + \log N)t \quad (17)$$

$$ECVI = F(\mathbf{S}; \hat{\Sigma}_{Mod}) + \frac{2t}{N - 1} \quad (18)$$

AIC (y CAIC) no siguen una distribución normal, por lo que no es posible interpretar directamente sus valores. Además, conviene señalar que estos índices suponen solamente medidas descriptivas, aunque pueden ser de utilidad para decidir entre modelos alternativos, permitiendo a los investigadores considerar la selección de aquel modelo que obtenga valores más pequeños.

Como ya se comentó, ECVI es un índice que ha sido recomendado por varios autores en la RPP. En la práctica, ECVI y AIC obtienen resultados muy parecidos, aunque los dos índices provienen de desarrollos y de lógicas distintas. En particular, AIC se aplica a una sola muestra mientras que ECVI desarrolla un procedimiento “dos-muestras”, una para calibrar el modelo y otra de validación. El valor que ofrece ECVI es un promedio de los distintos procedimientos “dos-muestras” elaborados para cada conjunto de datos. Además, presenta la ventaja de elaborar un intervalo de confianza (90% CI) para el valor aplicado sobre el modelo evaluado. Conviene señalar que el valor de ECVI calculado el modelo de independencia no está disponible en LISREL en versiones anteriores a la utilizada en este trabajo.

# CAPÍTULO 3

## Resultados

## CAPÍTULO 3: Resultados

Este capítulo se ha dividido en dos estudios: en el primero se muestran los resultados elaborados a partir de datos continuos (ESTUDIO 1) y en el segundo a partir de datos ordinales y dicotómicos con distintos tipos de distribución (ESTUDIO 2). Esta organización permite diferenciar los *outputs* generados al pre-evaluar el modelo de independencia a partir de datos ideales (datos continuos) y a partir de escenarios de medición más realistas, en consonancia con los contextos de aplicación más frecuentes en Psicología (datos ordinales y dicotómicos). Dado el elevado volumen de condiciones y de resultados generados, en ocasiones se recurre a Anexos para detallar algún tipo de información descrita a lo largo de este capítulo, aunque esta situación ha tratado de evitarse en la medida de lo posible. Los Anexos se han organizado a modo de fichas en función del tipo de datos generados y del número de variables observables por factor, y en ellas se describe toda la información cruzada respecto al resto de condiciones generadas.

Tanto el ESTUDIO 1 como el ESTUDIO 2 se han estructurado de la misma manera: 1) evaluación de la falta de convergencia en la estimación y de la aparición de casos *Heywood*, 2) calidad en la recuperación de parámetros, y 3) comportamiento de los distintos índices de ajuste descriptivo señalados en el Capítulo 2. Todos estos análisis distinguen entre aquellas soluciones en las que se rechaza  $H_0$  del modelo de independencia (soluciones T1) y en las que se mantiene (soluciones T2). Este capítulo se ha complementado con un tercer apartado (apartado 3.3) en el que se realizan estudios de potencia a partir de la información generada en el presente trabajo. En este apartado se muestran tanto los resultados obtenidos a partir de datos continuos como los obtenidos a partir de datos ordinales y dicotómicos.


### 3.1. ESTUDIO 1: datos continuos

#### 3.1.1. Problemas de convergencia y casos *Heywood*

Siguiendo el esquema propuesto, comenzamos exponiendo el porcentaje de soluciones no convergentes/impropias (IM) identificadas en la estimación de modelos a partir de datos continuos. Para la condición  $\lambda_{ij} = 0,2$  se aprecia que el porcentaje de soluciones IM disminuye gradualmente a medida que aumenta el tamaño muestral y, especialmente, a medida que aumenta el número de variables observables. Ateniéndonos al tamaño muestral y al estimador ML, la proporción de soluciones IM pasa de un 29,7% con  $N = 200$  a un 17% con  $N = 500$ . Esta proporción es mayor en el peor de los escenarios en cuanto al número de variables observables (42% con  $n = 4$ ), descendiendo hasta un 17,8% con  $n = 7$  (9,7% con  $n = 7$  y  $N = 500$ ), y prácticamente desapareciendo con  $n = 15$ . Estos resultados son muy similares a los encontrados por Ximénez (2006, 2016) para cargas simuladas entre 0,25 y 0,35, 12 variables observables y  $N = 100 - 500$ . Para la condición  $\lambda_{ij} = 0,3$  el número de soluciones IM es bastante menor que en la condición anterior, alcanzando solamente un 6,4% con  $N = 200$  y un 8% con  $n = 4$ , en ambos casos utilizando la estimación ML. Este tipo de soluciones prácticamente desaparecen a partir de  $N = 300$  o de  $n = 5$ . Todos estos resultados se pueden consultar en la Figura 4. En la condición  $\lambda_{ij} = 0,4$  los peores resultados están por debajo del 1%. Estos resultados son consistentes con los obtenidos por Gagné y Hancock (2006) y De Winter et al. (2009), que mostraron ratios muy reducidos de soluciones IM con  $\lambda_{ij} = 0,4$  y condiciones similares de  $n$  y de  $N$ .

Combinando todas las condiciones simuladas (estimación ML), el porcentaje de soluciones IM alcanza el 47,9% ( $\lambda_{ij} = 0,2$ ) y el 17,9% ( $\lambda_{ij} = 0,3$ ) en las peores condiciones posibles ( $N = 200$  y  $n = 4$ ). No obstante, con  $\lambda_{ij} = 0,2$ ,  $n = 7$  y  $N = 500$  el porcentaje de soluciones IM es de un 9,7%, y con  $n = 15$  es de un 3,1% con  $N = 200$ . En todas las condiciones simuladas el método ULS consigue estimar con éxito algunas soluciones IM que se producen con ML (Anexo B). Estos resultados son consistentes con la investigación previa (Ximénez, 2006, 2007).

Figura 4. Proporción de soluciones IM (datos continuos)




$\lambda_{ij} = 0,4$ : prácticamente no existen soluciones IM (en las peores condiciones el porcentaje de este tipo de soluciones es  $< 1\%$ , por lo que no se refleja en la Figura).

$2(\lambda_{ij}) \times 4(N) \times 5(n) \times 2(E) = 80$  condiciones experimentales.

Utilizando cargas factoriales heterogéneas (condiciones  $\lambda_{ij}$  (0,15-0,45) y  $\lambda_{ij}$  (0,1-0,5)) se obtiene un mayor número de soluciones IM que con magnitudes homogéneas. En la Figura 5 se muestran los resultados obtenidos a partir de ML. Se ha seleccionado la condición  $\lambda_{ij} = 0,3$  a la hora de comparar los resultados obtenidos a partir de cargas factoriales fijas y los obtenidos a partir de cargas heterogéneas. Así, con  $N = 200$  se observa que el porcentaje de soluciones IM asciende hasta un 21,1% en la condición  $\lambda_{ij}$  (0,15-0,45) y hasta un 9,9% en la condición  $\lambda_{ij}$  (0,1-0,5), frente al 17,9% y 8,2% obtenido con cargas fijadas a 0,3 en las mismas condiciones ( $N = 200$ ,  $n = 4$  y  $n = 5$ , respectivamente). Esta comparación no puede realizarse inspeccionando directamente las figuras expuestas, ya que en la Figura 7 se desagregan los resultados diferenciando entre la condición  $n = 4$  y  $n = 5$  para la variable  $N$ , siguiendo con el diseño planteado, mientras que en la Figura 4 la condición  $N = 200$  agrega todos los niveles de la variable  $n$ . Por este motivo, se hace necesario recurrir a los Anexos para mostrar la información relativa a este tipo de comparaciones.

Figura 5. Proporción de soluciones IM (datos continuos,  $\lambda_{ij}$  heterogéneas)



$1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 8$  condiciones experimentales.

Estimador ML.

### 3.1.2. Modelo de independencia y calidad en la recuperación de parámetros

Se evalúa a continuación el grado de discrepancia entre los parámetros simulados y los estimados en términos de ajuste teórico, precisión o calidad de la recuperación. Recordemos que las soluciones evaluadas en este apartado (y siguientes) no tienen en cuenta las soluciones IM. Una primera inspección de los resultados obtenidos sobre el ajuste teórico de las estimaciones arroja tres aspectos a destacar: *a)* como era esperable, el nivel de discrepancia entre los parámetros simulados y los estimados disminuye sistemáticamente a medida que mejoran las condiciones de aplicación cargas factoriales más altas, mayor número de observaciones y/o de indicadores, en línea con la investigación previa y en relación con el efecto compensatorio entre variables (por ejemplo, Gagné y Hancock, 2006; Mundfrom et al., 2005; Ximénez, 2006, 2007, 2009, 2016; De Winter et al., 2009), *b)* el nivel de discrepancia entre parámetros también se ve reducido sistemáticamente cuando se rechaza la  $H_0$  del modelo de independencia, y *c)* no todos los índices utilizados discriminan por igual entre las soluciones clasificadas como T1 ( $H_1$  modelo de independencia) y las clasificadas como T2 ( $H_0$  modelo de independencia). Estos últimos resultados no aparecen reflejados en la literatura previa.

Con el fin de resumir los resultados, vamos a comenzar por el tercero de estos aspectos. Se ha optado por realizar algunos análisis previos en relación a los cuatro índices de ajuste teórico utilizados ( $C_j$ ,  $RMSD_j$ ,  $ARB_j$  y  $AMSE_j$ ) con el fin de obtener alguna medida de sensibilidad respecto a la diferenciación de soluciones T1 y T2. Para ello, se ha calculado mediante ANCOVA el tamaño del efecto que tiene el test  $\chi^2_{Null}$  sobre cada uno de estos índices, controlando el efecto del resto de variables relevantes que determinan las condiciones de aplicación simuladas. El número de soluciones T1 y T2 se distribuye de forma heterogénea entre los distintos niveles del resto de variables analizadas, en algunos casos con proporciones

reducidas de soluciones T2. Se utiliza ANCOVA con el fin de potenciar la equivalencia de los dos grupos de comparación. Por simplicidad, se ha realizado ANCOVA sin tener en cuenta términos de interacción (ver Tabla 1).

Tabla 1. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ ,  $RMSD_j$ ,  $ARB_j$  y  $AMSE_j$ )

Efectos principales		$C_j$		$RMSD_j$		$ARB_j$		$AMSE_j$	
		$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$
Datos continuos	$\chi^2_{Null}$	,000	,022	,000	,002	,000	,003	,000	,002
	$N$	,000	,007	,000	,097	,000	,096	,000	,111
	$n$	,000	,030	,000	,111	,000	,077	,000	,097
	<i>Est.</i>	,713	,000	,092	,000	,347	,000	,092	,000
	$\chi^2_{Null}$	,000	,035	,000	,016	,000	,022	,000	,016
	$N$	,000	,039	,000	,151	,000	,134	,000	,151
	$n$	,000	,028	,000	,142	,000	,141	,000	,142
	<i>Est.</i>	,031	,000	,000	,000	,000	,000	,000	,000
	$\lambda_{ij} = 0,2$								
	$\lambda_{ij} = 0,3$								

$\chi^2_{Null}$ : factor compuesto por dos niveles o grupos de comparación (T1 y T2).

*Est.*: método de estimación (ML, ULS).

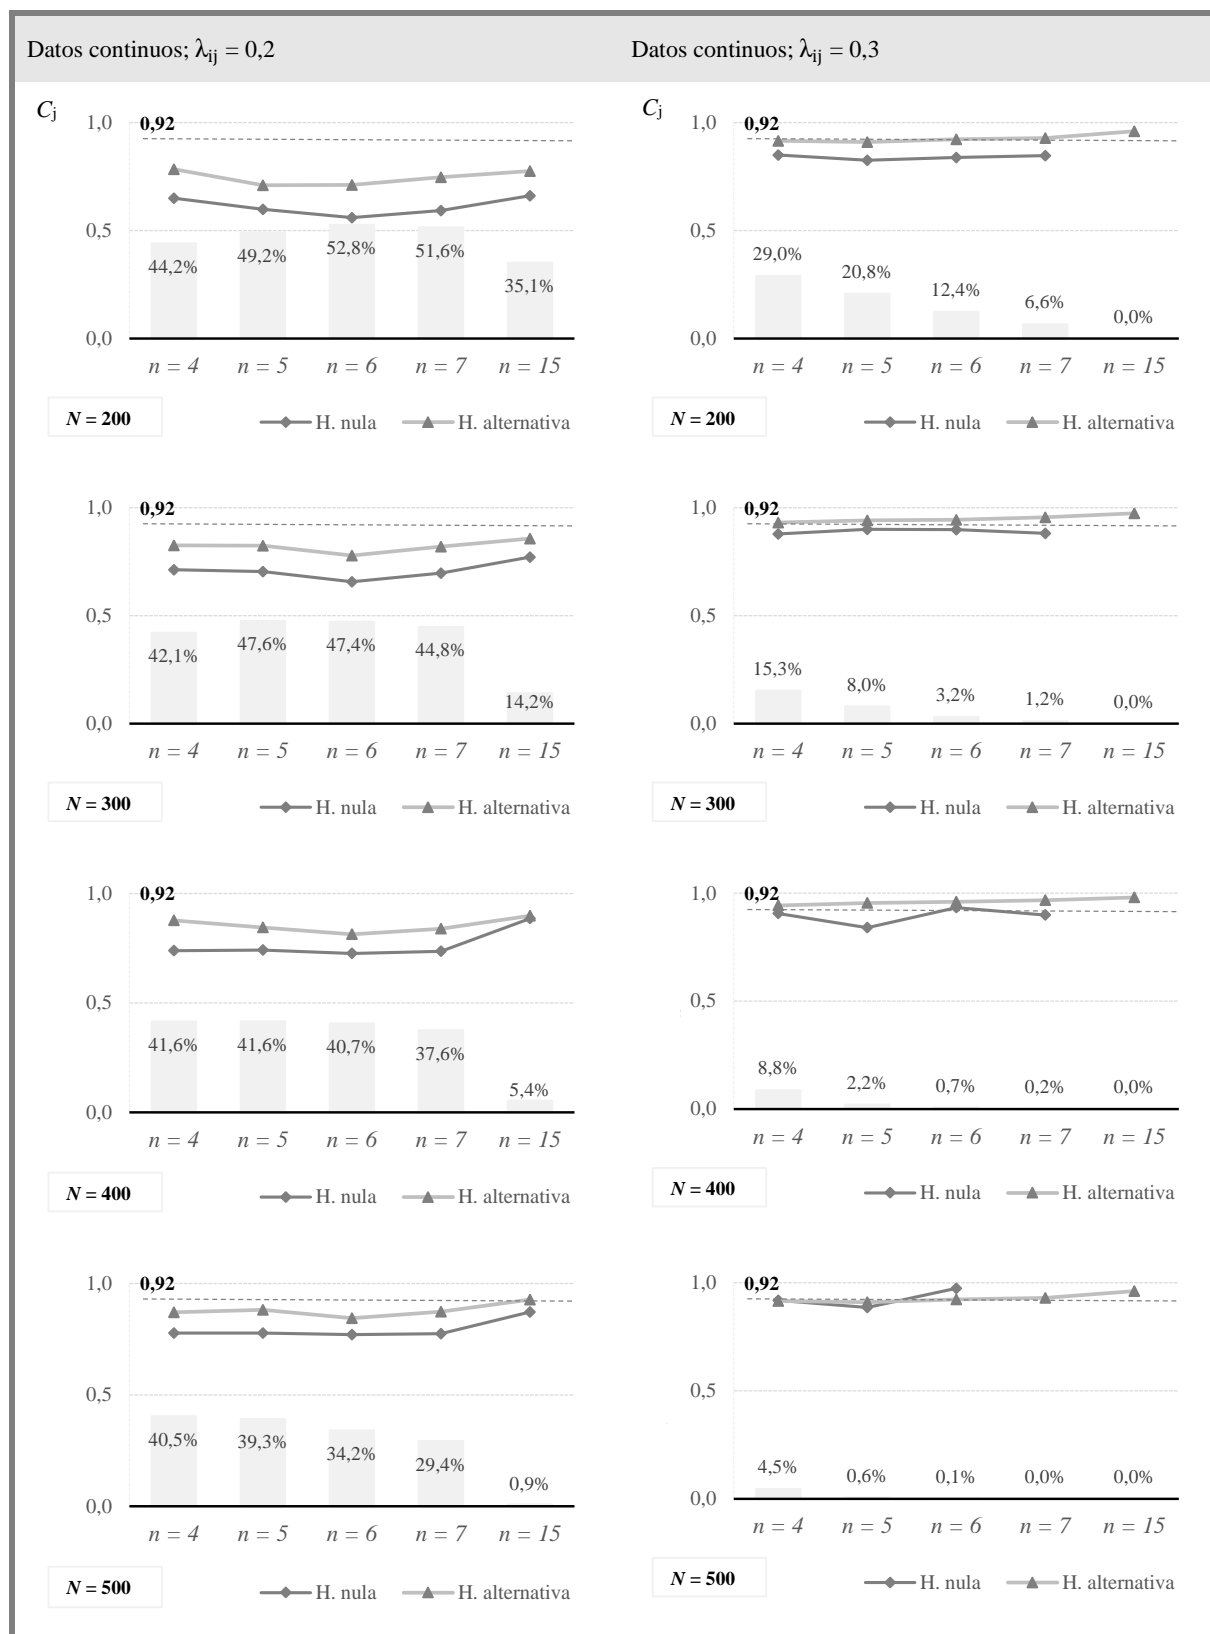
De los resultados anteriores se desprende que rechazar la  $H_0$  del modelo de independencia tiene un efecto mayor sobre  $C_j$  que en el resto de índices de ajuste teórico. Por otro lado (en Anexos), a nivel descriptivo la inspección de los valores promedio de todos estos índices muestra que tanto  $RMSD_j$  como  $AMSE_j$  no parecen ajustarse adecuadamente a las condiciones simuladas: en primer lugar,  $RMSD_j$  ha mostrado ser un índice de ajuste teórico poco sensible ya que se supera el punto de corte recomendado ( $< 0,20$ , ver Capítulo 2) con demasiada facilidad, incluso en simulaciones que reflejan malas condiciones de aplicación. En segundo lugar, y a la inversa,  $AMSE_j$  ha mostrado ser demasiado conservador, siendo muy difícil cumplir con las recomendaciones ( $< 10\%$ ) incluso en condiciones más favorables. Por su parte  $ARB_j$  tiene en general un comportamiento similar a  $C_j$ , aunque más irregular a lo largo de las distintas condiciones simuladas. Por todas estas razones, se ha elegido  $C_j$  como índice de ajuste teórico



para informar de los resultados obtenidos en este apartado, si bien los resultados indican que con cualquiera de estos índices se registra una mayor discrepancia en la recuperación de parámetros a medida que se empobrecen las condiciones de aplicación.

Fijándonos en los resultados obtenidos para datos continuos y estimación ML (Figura 6), podemos observar los dos primeros aspectos destacados más arriba: *a)* y *b)*. En primer lugar, el valor de  $C_j$  es sistemáticamente más elevado cuando el valor de las cargas factoriales simuladas es también más elevado; más concretamente,  $C_j$  es mayor sistemáticamente con  $\lambda_{ij} = 0,3$  que con  $\lambda_{ij} = 0,2$ . Este tipo de resultados son consistentes con la extensa literatura sobre métodos de estimación y recuperación de parámetros en AFC/SEM, y se manifiesta de forma generalizada a lo largo de todo el Capítulo 3, por lo que se obviará de aquí en adelante (salvo mención expresa). No obstante, conviene señalar que en algunas condiciones concretas se obtienen valores inusualmente elevados en soluciones T2. Esto puede deberse a situaciones en las que el ajuste teórico es muy bueno a pesar de la ausencia de varianza común, constituyendo un tipo de soluciones que tal vez no sean T1 o T2 “puras”. A pesar de ello, y a nuestro juicio, este tipo de soluciones deben entenderse como soluciones T2 ya que debe pesar más para su clasificación la ausencia de varianza común que el ajuste teórico. En este sentido, no serían falsos positivos, sino clasificaciones correctas de T2 ( $H_0$  del modelo de independencia). Por otro lado, este tipo de soluciones son muy escasas en buena parte de las condiciones, como se aprecia en las barras proyectadas en los gráficos de la Figura 6.

El segundo aspecto a destacar, que es uno de los aspectos novedosos planteados en el presente trabajo, es la tendencia a encontrar valores de  $C_j$  mayores en aquellas soluciones en las que se rechaza la  $H_0$  del modelo de independencia (soluciones T1). Estas diferencias son más evidentes con  $\lambda_{ij} = 0,2$  que con  $\lambda_{ij} = 0,3$ , aunque claras en ambos casos (especialmente en las condiciones de aplicación más limitadas).

Figura 6. Promedio de  $C_j$  por tipo de solución (T1-T2). Datos continuos (ML)

Se excluye la condición  $\lambda_{ij} = 0,4$  por acumular muy pocas soluciones T2 ( $H_0$  del modelo de independencia).

Las barras representan el porcentaje de soluciones T2.  $2(\lambda_{ij}) \times 4(N) \times 5(n) \times 1(E) = 40$  condiciones experimentales.

A medida que aumenta el tamaño muestral, estas diferencias decrecen con  $\lambda_{ij} = 0,3$ , aunque de manera simultánea al decrecimiento del porcentaje de soluciones T2. Con  $\lambda_{ij} = 0,2$ , el promedio de  $C_j$  en las soluciones T1 no alcanza el valor recomendado ( $\geq 0,92$ ) en la mayoría de las condiciones. No obstante, al tratarse de valores promedio lo esperable es que algunas soluciones específicas sí cumplen con dicha recomendación. En el caso de  $\lambda_{ij} = 0,3$  el valor promedio de  $C_j$  se encuentra próximo al valor recomendado (o incluso por encima) en el conjunto de soluciones T1.

Para comparar la calidad de la recuperación entre las soluciones T1 y T2 en las condiciones simuladas con cargas heterogéneas, se ha vuelto a realizar un ANCOVA (efectos principales) cuyo resultado se muestra en la Tabla 2. Nuevamente, el índice de ajuste teórico que refleja una mayor sensibilidad para discriminar entre soluciones T1 y T2 es el coeficiente de congruencia ( $C_j$ ). Para simplificar la exposición de resultados se ha descrito únicamente este índice (ver Figura 7).

Tabla 2. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ ,  $RMSD_j$ ,  $ARB_j$  y  $AMSE_j$ ): niveles heterogéneos de lambda ( $\lambda_{Het.}$ )

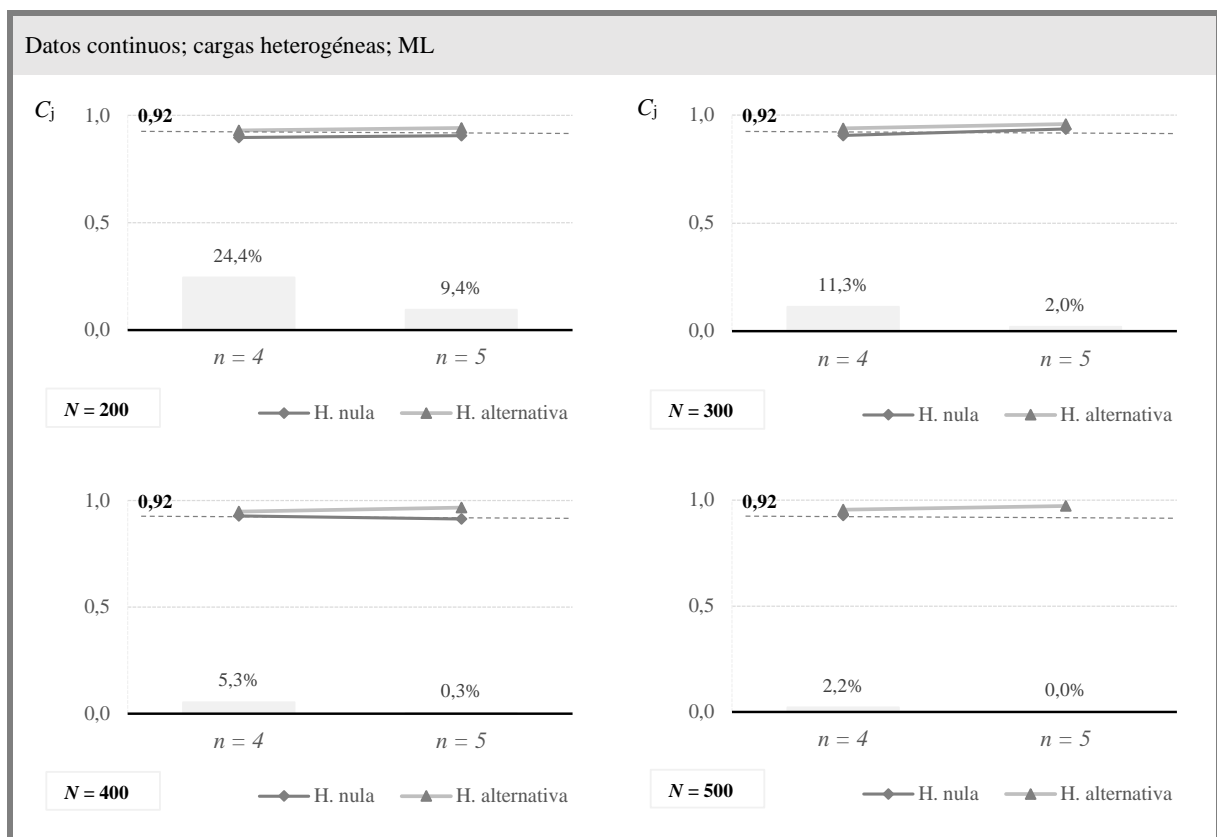
Efectos principales			$C_j$		$RMSD_j$		$ARB_j$		$AMSE_j$	
			$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$
Cont.	$\lambda_{Het.}$ ML	$\chi^2_{Null}$	,000	,024	,000	,002	,000	,004	,151	,000
		$N$	,000	,047	,000	,082	,000	,080	,000	,093
		$n$	,000	,028	,000	,048	,000	,051	,001	,001

$\chi^2_{Null}$ : factor compuesto por dos niveles o grupos de comparación (T1 y T2).

En la Figura 7 se observa que las discrepancias entre los parámetros simulados y estimados son muy similares al comparar las soluciones T1 y las T2. Se puede observar que la proporción de soluciones T2 ha disminuido respecto a las condiciones simuladas con cargas fijadas en 0,3 (nivel de referencia): por ejemplo, se ha pasado de un 29% a un 24,4% con  $N =$

200 y  $n = 4$ . Al existir parámetros poblacionales fijados a 0,45 y 0,35 (0,5 y 0,4 en la condición  $n = 5$ ), las condiciones con cargas heterogéneas parecen potenciar el rechazo de la  $H_0$  del modelo de independencia, a pesar de existir otras cargas fijadas en 0,15 y 0,25 (0,1 y 0,2 en la condición  $n = 5$ ). No obstante, el mayor problema en este tipo de modelos es que presentan una proporción mayor de soluciones IM, por lo que su evaluación debería sustentarse en un mayor número de observaciones y/o de variables observables. En este sentido, las cargas simuladas más altas favorecen la calidad de la recuperación y la obtención de soluciones T1 (niveles de  $\lambda_{ij}$  que son más fáciles de detectar), pero al mismo tiempo las cargas más bajas favorecen la presencia de soluciones IM, claro síntoma de falta de sensibilidad del AFC en las condiciones evaluadas.

Figura 7. Promedio de  $C_j$  por tipo de solución (T1-T2). Datos continuos (ML), cargas heterogéneas



Las barras representan el porcentaje de soluciones T2.

$1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 8$  condiciones experimentales.

### 3.1.3. Modelo de independencia e índices descriptivos de ajuste

Los resultados que se exponen a continuación se han organizado en tres apartados. Siguiendo la distinción realizada en estudios previos (Heene et al., 2011), el primer apartado hace referencia a aquellos índices de ajuste descriptivo ( $\chi^2_0$ , RMSEA y SRMR) que son insensibles a la sobreparametrización y que podrían confundir al investigador aplicado ya que ofrecen valores que cumplen con las recomendaciones generales de ajuste. El segundo hace referencia a aquellos índices (NNFI y CFI) que utilizan el valor de  $\chi^2_{Null}$  en su formulación, comparándolo con el valor de  $\chi^2_0$  en función de sus respectivos grados de libertad. Por último, se valoran los resultados obtenidos para los índices ECVI<sub>r</sub>, AIC<sub>r</sub> y CAIC<sub>r</sub>, que no recibieron atención en la literatura previa y que se proponen en este trabajo como índices alternativos de aproximación. Estos tres apartados se consideran nuevamente en el ESTUDIO 2 (datos ordinales y dicotómicos).

Los resultados se han organizado realizando dos tipos de comparaciones. Se ha comparado si los índices descriptivos de ajuste permiten diferenciar entre soluciones T1 y T2. A continuación, se valora el grado en el que cada índice se relaciona con el ajuste teórico de los modelos estimados dentro de las soluciones T1, comparando distintos niveles de  $C_j$ . Esta comparación en función del nivel de ajuste teórico se muestra al final del apartado 3.2.3 del ESTUDIO 2.

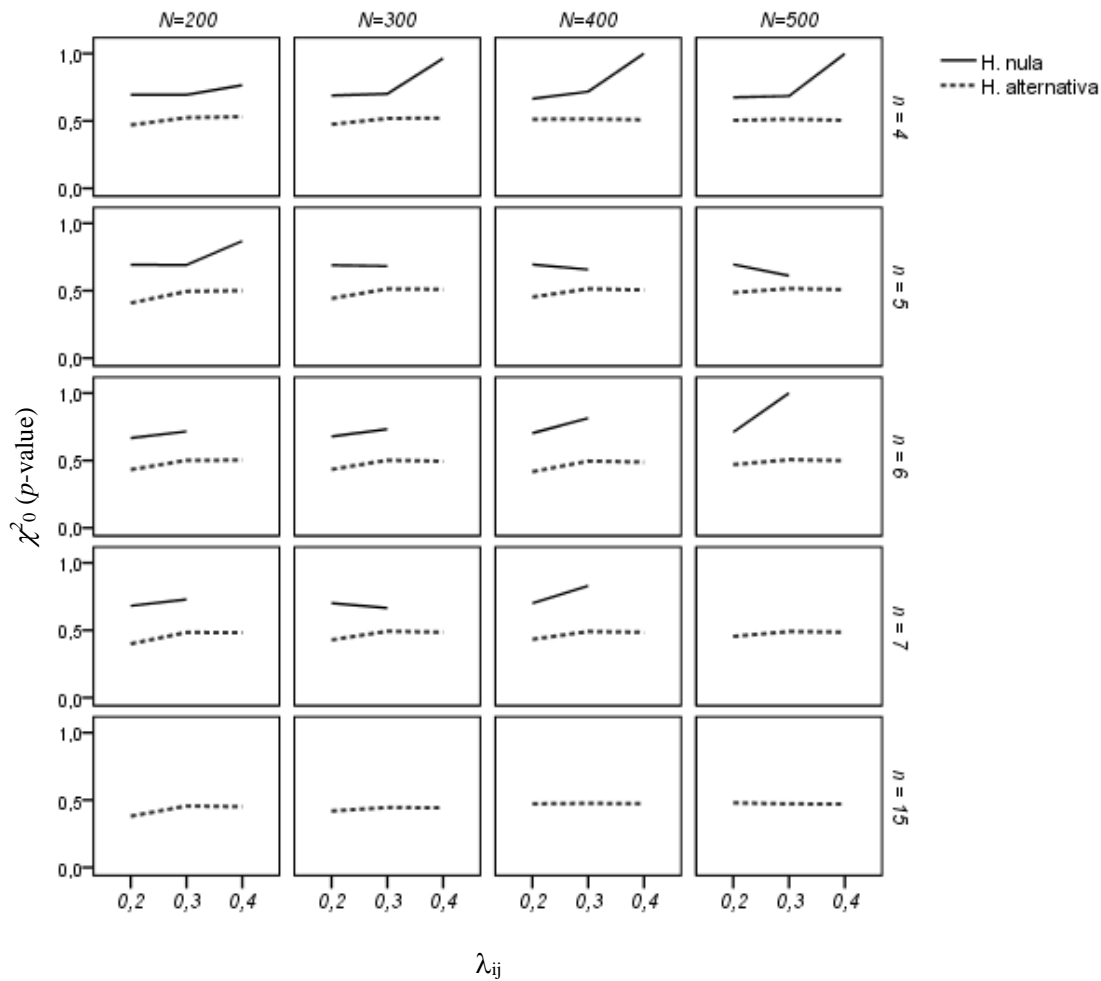
#### $\chi^2_0$ , RMSEA y SRMR

A nivel descriptivo, se observa que tanto el valor de  $\chi^2_0$ , como su nivel crítico (*p-value*), el valor de RMSEA y el de SRMR son indicativos de una mayor aproximación entre  $\hat{\Sigma}_0$  y  $S$

cuando se mantiene la  $H_0$  del modelo de independencia (soluciones T2). Esto es, cuando el modelo evaluado puede equipararse estadísticamente con el modelo de independencia poblacional se obtienen valores más bajos de  $\chi^2_0$ , RMSEA y de SRMR, lo que refleja un mayor ajuste. A nivel promedio, los resultados que reflejan estos índices cumplen con los puntos de corte y con las recomendaciones habituales (por ejemplo, Marsh et al., 2005) en la inmensa mayoría de las condiciones simuladas (Anexos).

Estudios previos (Heene et al., 2011) mostraron que estos índices son insensibles a la sobreparametrización de los modelos, en el sentido de ofrecer valores indicativos de ajuste según las recomendaciones habituales en situaciones en las que existe un elevado grado de unicidad. En resumen, uno de los aspectos en los que inciden estos autores es que el aumento de la unicidad deriva en una considerable pérdida de potencia estadística del test  $\chi^2_0$  y de los índices RMSEA y SRMR (índices que se obtienen a partir de la comparación entre la matriz de varianzas-covarianzas empírica y reproducida). En consecuencia, los valores que se obtienen tras la estimación de los modelos tienden a ser bajos. No obstante, si bien nuestros resultados son coherentes con esta falta de sensibilidad, la distinción entre soluciones T1 y T2 nos ha permitido dar un paso más en la interpretación de este tipo de resultados. Más concretamente, la comparación del comportamiento de estos índices entre las soluciones T1 y T2 podría indicar que no se obtienen valores más ajustados a medida que aumenta la unicidad, como plantearon dichos autores. Donde se produce un mejor comportamiento de los índices es en las soluciones T2, manteniéndose de forma más o menos constante en las soluciones T1 (independientemente de la magnitud de la carga factorial simulada). En caso de no poner a prueba la  $H_0$  del modelo de independencia, unos resultados se combinan con otros, mostrando que los índices mejoran a medida que las cargas factoriales simuladas son más bajas. En la Figura 8 se muestra la distribución del valor promedio del nivel crítico de  $\chi^2_0$  con el fin de ilustrar esta situación.

Figura 8. Promedio nivel crítico de  $\chi^2_0$  en función del test  $\chi^2_{Null}$ . Datos continuos, estimación ML



En la figura anterior puede observarse cómo en las soluciones T1 (“H. alternativa”), el valor promedio del nivel crítico de  $\chi^2_0$  se mantiene de manera más o menos constante en todas las condiciones analizadas, incluso llegando a disminuir cuando  $\lambda_{ij} = 0,2$ . Por el contrario, es en las soluciones T2 en donde el nivel crítico se aleja más del nivel de significación  $\alpha = 0,05$ . Esta situación se refleja todavía más claramente en aquellas condiciones en las que no existen soluciones T2, como en  $n = 15$  o en  $n = 7$  y  $N = 500$ . Estas tendencias son prácticamente idénticas al comparar los valores promedio de RMSEA y SRMR. Por tanto, si no se identifican y eliminan previamente las soluciones T2, estos valores promedio se combinan dando lugar a una mejoría en el comportamiento de estos índices a medida que aumenta la unicidad. No existe

constancia de que en el estudio de Heene et al. (2011) se haya realizado este proceso de pre-evaluación. No obstante, conviene señalar que las cargas factoriales estimadas son sistemáticamente más bajas en las soluciones T2 (ver Anexo F), por lo que parece que finalmente sí mejora el ajuste a medida que aumenta la unicidad. Estos resultados parecen poner de relieve una situación compleja que requeriría de una mayor profundización y análisis, lo que excede los objetivos del presente trabajo. En cualquier caso, ninguno de estos índices resulta de utilidad para detectar los problemas evaluados en el presente trabajo, existiendo claros problemas de potencia como sí indicaron los autores citados.

#### NNFI y CFI

Comenzando por NNFI, los resultados obtenidos indican dos aspectos de interés: el primero hace referencia a la fuerte tendencia de este índice a obtener valores fuera del rango de las recomendaciones habituales. Aunque NNFI se suele interpretar de forma similar a CFI (valores próximos a 1 indican un buen ajuste del modelo, asumiendo un rango de valores entre 0 y 1), puede adoptar valores fuera de rango (Bentler, 1990; Mulaik, 2009). Nuestros resultados indican que existe una fuerte tendencia de NNFI a presentar valores fuera de rango especialmente en las soluciones T2, aunque también en las soluciones T1 (Anexos). En otras palabras, los valores fuera de rango son más extremos en T2 que en T1. Por lo tanto, parece que NNFI no es un índice recomendable cuando se realizan este tipo de pre-evaluaciones, ya que plantearía el problema de qué valores fuera de rango indican desajuste o una buena aproximación. El segundo aspecto de interés, a nivel de tendencias, es que los mayores desajustes se producen en T2, invirtiéndose así la tendencia observada en  $\chi^2_0$ , RMSEA y SRMR. Este segundo aspecto también se ha podido observar respecto al índice CFI. En el caso de este último índice no existen problemas de valores fuera de rango, ya que la elaboración de

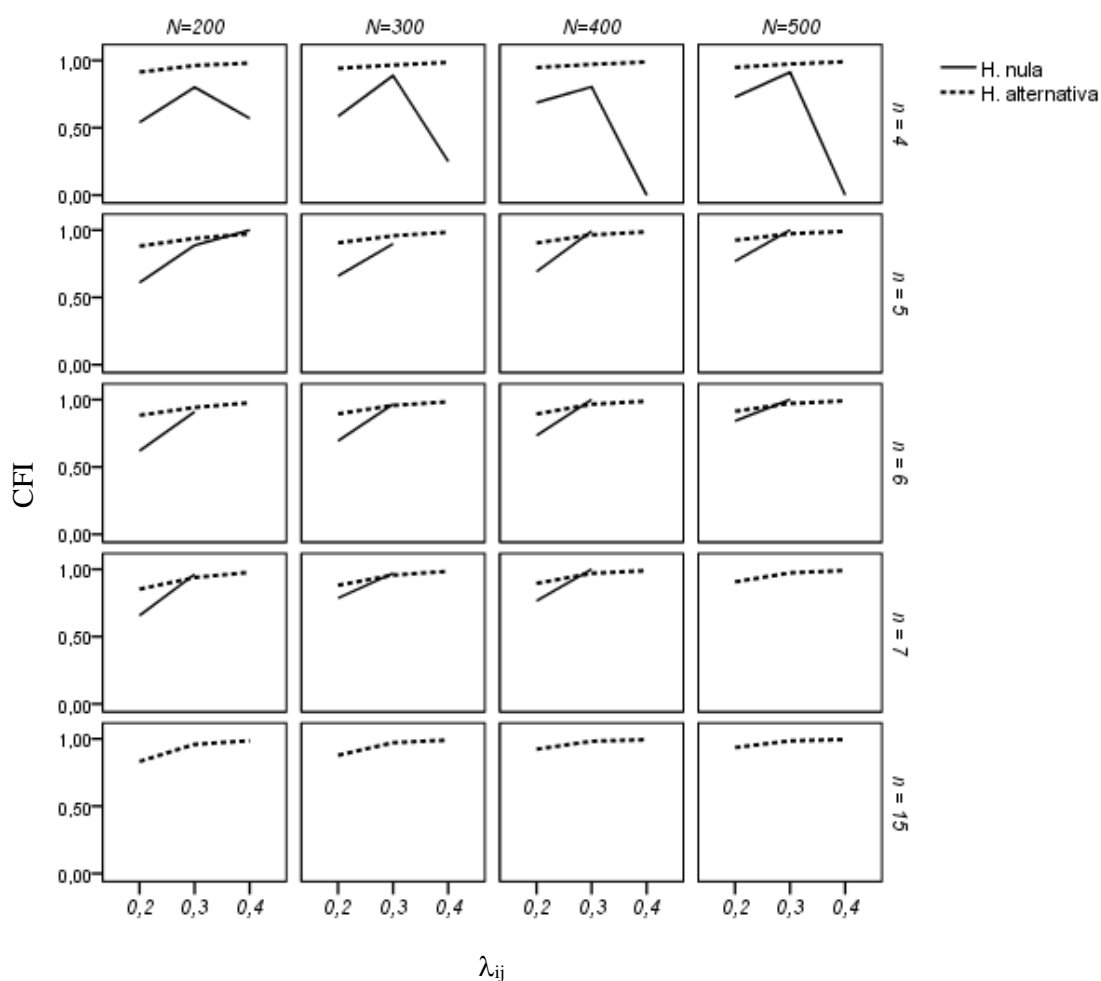


CFI no permite obtener valores por debajo de 0 o por encima de 1. En la mayoría de las condiciones simuladas el valor de CFI es inferior en las soluciones T2 que en las T1, obteniendo valores promedio dentro de los puntos de corte recomendados en las condiciones con más indicadores y con mayor número de observaciones. No obstante, un problema que presenta este índice es que en varias de estas condiciones se obtienen promedios dentro de los rangos recomendados también en las soluciones T2. Excede de los objetivos del presente trabajo ofrecer justificaciones sobre los motivos por los que esto sucede. Tal vez no sea un problema de los índices sino de los puntos de corte establecidos (en este sentido, podría ser más adecuada la utilización de NFI y de RFI, en Anexos). También convendría revisar si las condiciones de aplicación en las que se fundamentan los puntos de corte (modelos multidimensionales, infraparametrización; ver Hu y Bentler, 1998, 1999) son comparables a las desarrolladas en este trabajo.

Heene et al. (2011) también analizaron el índice CFI y obtuvieron resultados distintos, esto es, CFI era mayor a medida que aumentaba el nivel de unicidad. Estos autores indican que, dado que este índice compara el valor de  $\chi^2_0$  con el de  $\chi^2_{Null}$ , disminuyen las diferencias entre ambos valores de  $\chi^2$  a medida que aumenta la unicidad. En la Figura 9 se muestran los valores promedio de CFI para las soluciones T1 y T2 calculados en el presente trabajo. Estos resultados podrían explicar, al menos en parte, las diferencias con los resultados obtenidos en la investigación previa. En el nivel de  $\lambda_{ij} = 0,3$  las soluciones T2 tienen un promedio en CFI igual o superior al de las soluciones T1 en varias de las condiciones, resultado similar al encontrado por Heene et al. (2011). Estos autores centraron su evaluación en valores simulados de  $\lambda_{ij}$  entre 0,3 y 0,4. Conviene señalar también que entre el estudio presentado por estos autores y los estudios realizados en el presente trabajo existen importantes diferencias de diseño (en el estudio previo se utilizaron modelos con tres factores, con  $n = 15$  y  $45$ , y sin proceso de pre-

evaluación). La comparación entre los resultados previos y los presentados en este trabajo debe realizarse con mucha cautela, requiriendo de investigación adicional.

Figura 9. Promedio de CFI en función del test  $\chi^2_{\text{Null}}$ . Datos continuos, estimación ML



### ECVI, AIC y CAIC

Recordemos que los índices que se presentan a continuación se han elaborado dividiendo el valor asociado al modelo de independencia por el valor asociado al modelo evaluado y que estos índices reflejan mayor ajuste comparativo cuanto menor es su valor. Un valor por encima de 1 indica que cualquiera de estos índices aplicado sobre el modelo de independencia es mayor que el aplicado sobre el modelo evaluado, por lo que resulta mejor este último (ajusta mejor).

Los resultados muestran un comportamiento muy similar entre  $ECVI_r$  y  $AIC_r$ , de forma coherente a los comentarios realizados sobre estos índices al final del Capítulo 2. Los análisis realizados reflejan la tendencia a obtener sistemáticamente valores de  $ECVI_r$  y  $AIC_r > 1$  en las soluciones T1, y más elevados que los obtenidos en las soluciones T2. En las peores condiciones de simulación incluso estos índices llegan a obtener valores promedio por debajo de 1, especialmente  $ECVI_r$ . A medida que aumenta el número de variables observables,  $AIC_r$  obtiene valores promedio por encima de 1 en T2 incluso en las condiciones  $\lambda_{ij} = 0,2$  y  $N = 200 - 300$ , aunque claramente diferenciados de los valores obtenidos en T1 (Anexos). Para simplificar la exposición de resultados hemos escogido solamente el índice  $ECVI_r$  al ser el que cuenta con más respaldo entre distintos autores, tal y como refleja la RPP, y al ser el índice recomendado en la estrategia de pre-evaluación propuesta en este trabajo. Adicionalmente, elegimos este índice por tener una lógica directamente relacionada con la replicabilidad de la estimación del modelo AFC en nuevas muestras. Por su parte, si bien  $CAIC_r$  sigue la lógica recién expuesta, los resultados obtenidos reflejan un resultado más conservador, ya que se obtienen valores promedio  $> 1$  solamente en las soluciones T1 y en condiciones en las que se simulan más indicadores y más observaciones.

A diferencia de los índices de ajuste analizados más arriba ( $\chi^2_0$ , RMSEA, SRMR, NNFI y CFI), tanto  $ECVI_r$  como  $CAIC_r$  muestran una mejoría clara en las soluciones T1 a medida que aumenta el nivel de carga factorial simulado (ver Figuras 10 y 11). Además, estos índices no solo resultan sensibles a la presencia de soluciones T1 y T2 (a diferencia de  $\chi^2_0$ , RMSEA y SRMR) sino que su buen comportamiento de refleja de manera sistemática en las condiciones simuladas (a diferencia de CFI).

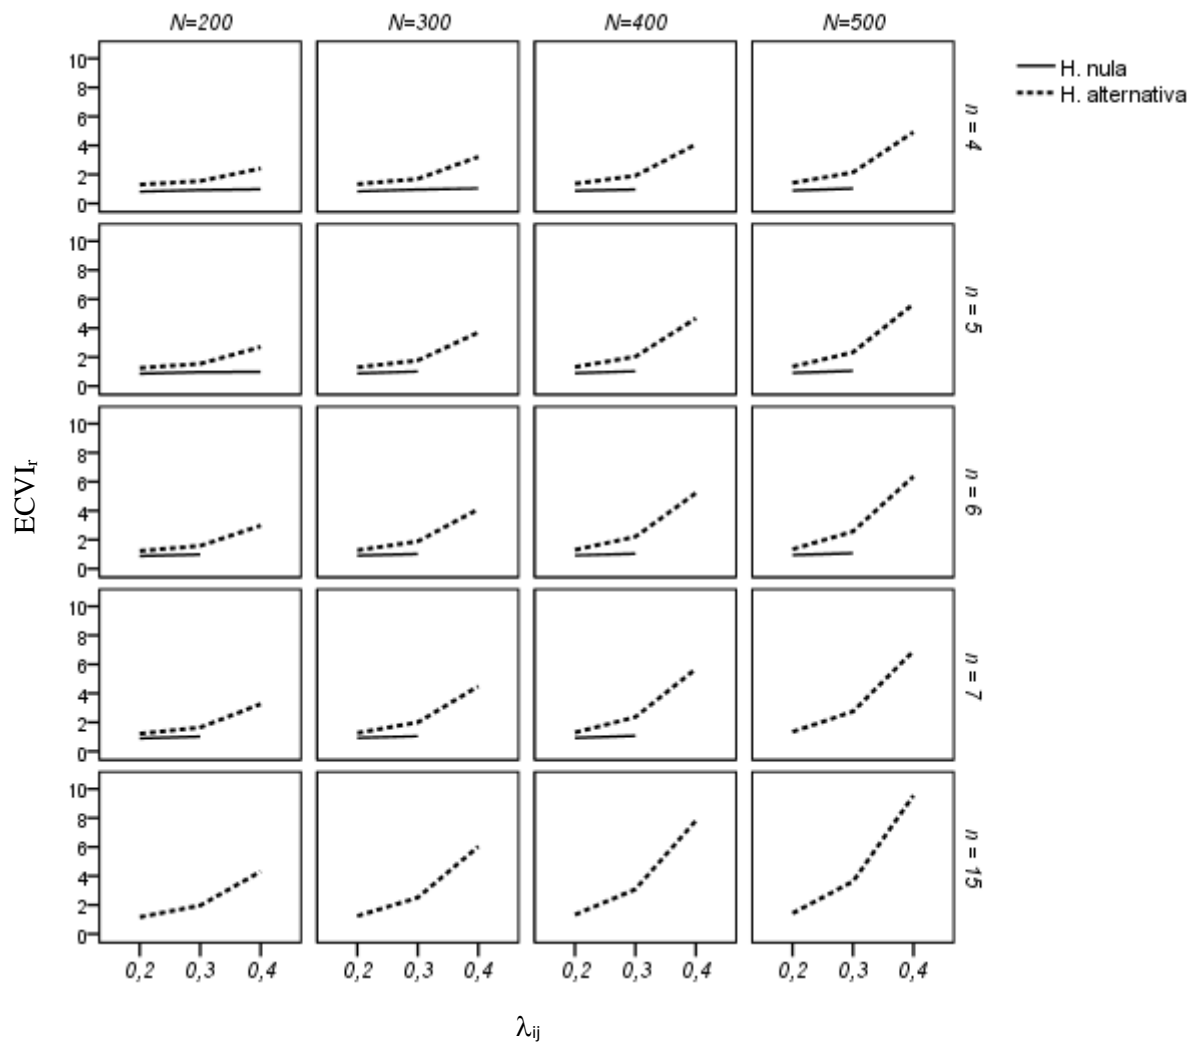
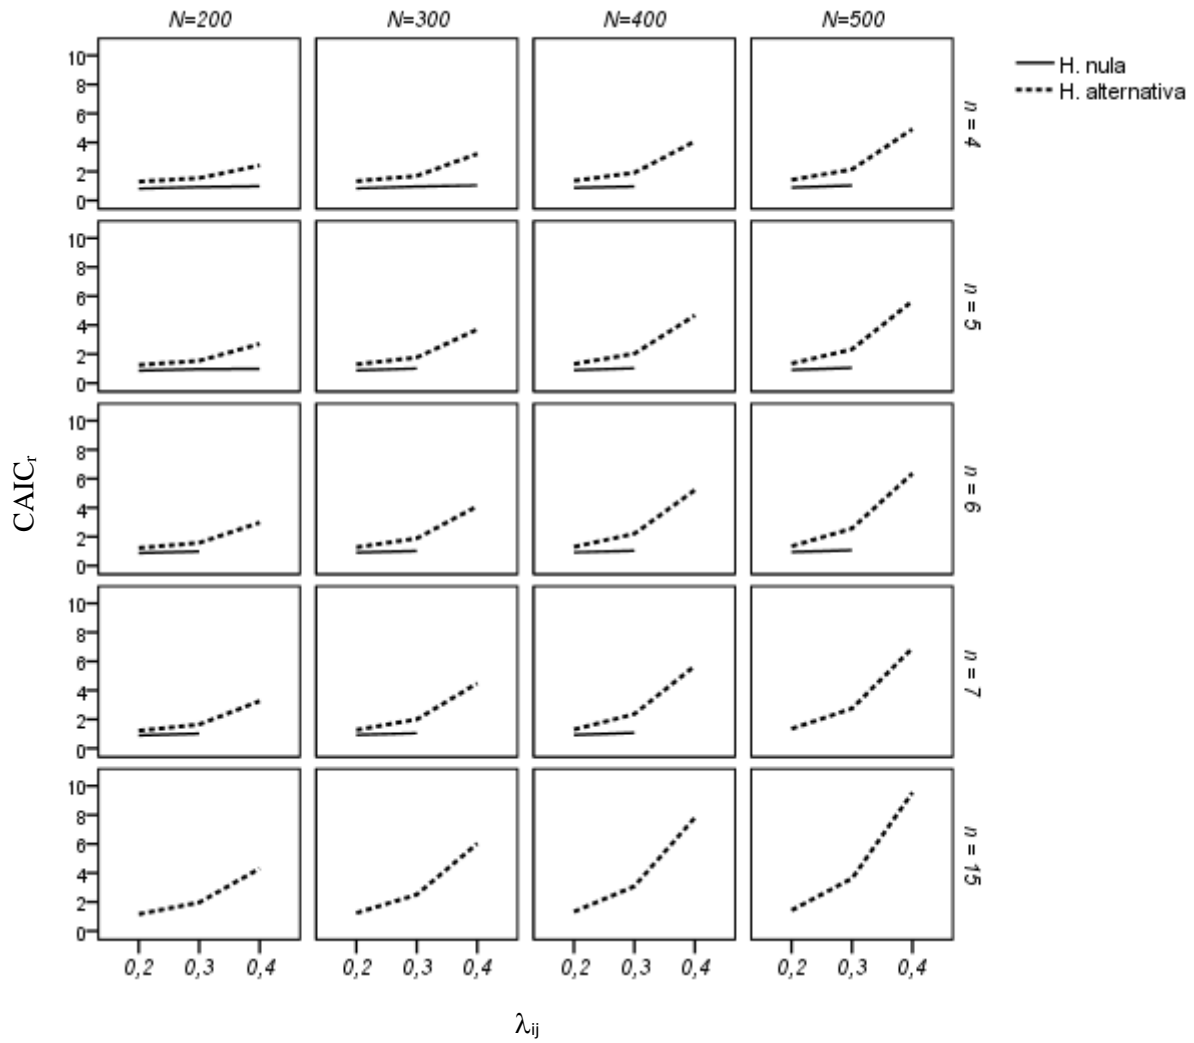
Figura 10. Promedio de  $ECVI_r$  en función del test  $\chi^2_{Null}$ . Datos continuos, estimación ML

Figura 11. Promedio de  $CAIC_r$  en función del test  $\chi^2_{Null}$ . Datos continuos, estimación ML.




## 3.2. ESTUDIO 2: datos ordinales y dicotómicos

### 3.2.1. Problemas de convergencia y casos *Heywood*

Una vez identificada la proporción de IM con datos continuos en el ESTUDIO 1, se comparan dichos resultados con las simulaciones realizadas con los datos ordinales (5 categorías) y con los datos dicotómicos, más propios de contextos de investigación realistas. Como se comentó en el Capítulo 2, se ha procedido secuencialmente con el fin de simplificar la exposición de resultados. Por esta razón, en los análisis realizados sobre datos ordinales y dicotómicos no se utiliza la condición  $\lambda_{ij} = 0,2$ . Como se vio en el ESTUDIO 1, esta condición resulta problemática incluso con datos ideales, resultando razonable pensar que los resultados empeorarán con datos más realistas. Con datos discretos los problemas de estimación serán aún peores, pudiendo establecerse una especie de valor techo a partir de los resultados obtenidos con los datos continuos. Tampoco se utilizan las condiciones  $n = 7$  ni  $n = 15$ . Con datos continuos, estas condiciones mejoran notablemente la convergencia de las estimaciones (y evitan la presencia de casos *Heywood*). Si bien se puede asumir que con datos discretos las soluciones IM estarán más presentes, se puede extrapolar que aumentar el número de indicadores es una forma de evitar este tipo de soluciones. En el ESTUDIO 2 se analiza también el efecto de distintos tipos de distribución presente en los datos. En términos generales, y salvando las diferencias de diseño entre estudios, todos los resultados que se exponen en este apartado son consistentes con los encontrados por Forero, Maydeu-Olivares, y Gallardo-Pujol (2009).

En las simulaciones realizadas a partir de datos ordinales (5 categorías;  $\lambda_{ij} = 0,3$ : ver Figura 12), el mayor número de soluciones IM se produce en la condición 5D2 (24,3%), la distribución con mayor nivel de asimetría. Cuando se trabaja con  $N = 200$  se produce un 22,4% de soluciones IM, mientras que cuando el factor tiene 4 variables observables esta proporción se manifiesta en un 19,2% de los modelos evaluados. Los datos anteriores se refieren a la estimación RML, la que peores resultados ha obtenido. Los estimadores RDWLS y RULS consiguen una proporción de soluciones IM ligeramente inferior. Las distribuciones 5D1 (simétrica) y 5D3 (uniforme) obtienen resultados muy similares.


Figura 12. Proporción de soluciones IM (datos ordinales: 5 categorías,  $\lambda_{ij} = 0,3$ )



$3(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 108$  condiciones experimentales.

Comparando los resultados obtenidos en la distribución 5D1 con las estimaciones realizadas con datos continuos, se observa una mayor proporción de soluciones IM cuando se trabaja con este tipo de datos. En las peores condiciones ( $n = 4$  y  $N = 200$  para  $\lambda_{ij} = 0,3$  se obtiene un 17,9% de soluciones IM con ML, frente a un 19,7% con RDWLS). En estas condiciones, y con distribución asimétrica de los datos (5D2), la proporción de soluciones IM es de un 40,3% (RDWLS). Este tipo de problemas se manifiesta con poca intensidad en las distribuciones 5D1 y 5D3 cuando se trabaja con  $N = 400$  ( $n = 4$ ) o a partir de  $N = 300$  ( $n = 5$ ), especialmente con los estimadores RDWLS y RULS. Estos problemas de estimación prácticamente desaparecen con  $n = 6$ , obteniéndose resultados muy similares a los obtenidos con datos continuos (en Anexos).  $\lambda_{ij} = 0,4$  presenta una clara reducción en el porcentaje de soluciones IM (Figura 13), incluso en la condición en las que los datos presentan un elevado grado de asimetría (5D2), Con  $N = 200$  el porcentaje de soluciones IM es de un 7,4% y con  $n = 4$  es de un 6,4% (en ambos casos, nos referimos a la estimación RDWLS). Combinando ambas condiciones el porcentaje de soluciones IM asciende a un 15,2%, y con  $N = 300$  o  $n = 5$  /  $n = 6$  esta proporción se mantiene en valores en torno al 10% o inferiores.

Figura 13. Proporción de soluciones IM (datos ordinales: 5 categorías,  $\lambda_{ij} = 0,4$ )




$1(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 36$  condiciones experimentales.



En las simulaciones realizadas a partir de datos dicotómicos ( $\lambda_{ij} = 0,3$ , estimación RDWLS: ver Figura 14), el mayor número de soluciones IM (21,4%) se produce en la condición 2D3, la distribución con mayor nivel de asimetría. Cuando se trabaja con  $N = 200$  se produce un 27,4% de soluciones IM, mientras que en la condición  $n = 4$  la proporción es de un 26,9%. Como puede apreciarse, los problemas de convergencia y/o la presencia de casos *Heywood* se intensifican considerablemente cuando se pasa de analizar datos continuos a datos dicotómicos.


Figura 14. Proporción de soluciones IM (datos dicotómicos,  $\lambda_{ij} = 0,3$ )



$3(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 108$  condiciones experimentales.

En la condición  $\lambda_{ij} = 0,4$  y distribución más asimétrica (Figura 15), se ha obtenido un 10,9% de soluciones IM con  $N = 200$  y un 9,7% con  $n = 4$  (estimación RDWLS). Nuevamente, aumentar el nivel de carga factorial de las simulaciones mejora sensiblemente la estimación de los modelos. En las peores condiciones ( $N = 200, n = 4$ ) se alcanza un 20,5% de soluciones IM. Como ocurre en los resultados anteriores, aumentar el tamaño muestral y/o el número de variables observables hace mejorar rápidamente estos resultados.

Figura 15. Proporción de soluciones IM (datos dicotómicos,  $\lambda_{ij} = 0,4$ )




$1(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 3(E) = 36$  condiciones experimentales.

Nuevamente, la comparación del porcentaje de soluciones IM que se obtiene a partir de la simulación de cargas factoriales heterogéneas (condiciones  $\lambda_{ij}$  (0,15-0,45) y  $\lambda_{ij}$  (0,1-0,5)) con las obtenidas en la condición que fija la carga en 0,3, arroja resultados más desfavorables en el primer tipo de modelos. Para una rápida inspección, en las Figuras 16 y 17 se muestran los resultados obtenidos a nivel global tanto para los datos ordinales como para los dicotómicos. Para datos ordinales y  $n = 4$ , la proporción de IM en los modelos con cargas fijadas en 0,3 es de un 19,7%, mientras que para la condición  $\lambda_{ij}$  (0,15-0,45) es de un 21,5% (5D1,  $N = 200$  y estimador RDWLS). En las mismas condiciones pero en distribuciones más asimétricas (5D2),

con cargas fijadas en 0,3 existe un 40,3% de IM, por un 44,5% en la condición  $\lambda_{ij}$  (0,15-0,45).

Con  $n = 5$ , 5D1,  $N = 200$  y RDWLS se pasa de un 7,8% de soluciones IM para  $\lambda_{ij} = 0,3$  a un 9,8% para  $\lambda_{ij}$  (0,15-0,45), y de un 25,6% a un 30,3% en 5D2, respectivamente. Esta información puede consultarse más detalladamente en los Anexos.

Figura 16. Proporción de soluciones IM (datos ordinales: 5 categorías,  $\lambda_{ij}$  = heterogéneas)




$2(D) \times 1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 16$  condiciones experimentales.

Estimador RDWLS.

Para datos dicotómicos ( $n = 4$ ), la proporción de soluciones IM en los modelos con cargas fijadas en 0,3 es de un 35,7%, frente a un 39,7% con cargas heterogéneas (2D1,  $N = 200$  y estimador RDWLS). Con 2D3 se pasa de un 40,2% a un 44,9%, respectivamente. Con  $n = 5$ , se pasa de un 23,9% a un 22,7% (2D1,  $N = 200$  y RDWLS), y de un 34,9% para  $\lambda_{ij} = 0,3$  a un 34,7% (2D3,  $N = 200$  y RDWLS). Con 5 variables observables, este tipo de soluciones se producen de forma similar tanto con cargas homogéneas como con cargas heterogéneas.

Figura 17. Proporción de soluciones IM (datos dicotómicos,  $\lambda_{ij}$  heterogéneas)




$2(D) \times 1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 16$  condiciones experimentales.

Estimador RDWLS.


Por último, se pasa ahora a comentar los problemas de estimación encontrados para aquellas simulaciones con 3 variables observables ( $n = 3$ ). Recordemos que estas simulaciones solamente se han realizado para datos ordinales y dicotómicos, y que en todos los casos se utiliza el estimador RDWLS solo a efectos de uso del software. También, recordemos que se ha analizado una condición adicional,  $\lambda_{ij} = 0,5$ , ya que al simular factores representados por pocas variables observables se esperaba encontrar una mayor proporción de soluciones con problemas de convergencia y/o *Heywood* que en el resto de condiciones simuladas.

Con datos ordinales, la proporción de soluciones IM desciende drásticamente a medida que aumenta el nivel de carga factorial: pasamos de un 23,6% con  $\lambda_{ij} = 0,3$ , a un 5,2% con  $\lambda_{ij} = 0,4$ , y a un 0,8% con  $\lambda_{ij} = 0,5$  (ver Figura 18). También desciende rápidamente la proporción de este tipo de soluciones a medida que aumenta el número de observaciones. Por ejemplo, se pasa de un 42,9% con  $N = 200$  a un 24,7% con  $N = 500$  en el nivel  $\lambda_{ij} = 0,3$ . De manera combinada, para  $\lambda_{ij} = 0,3$  se obtiene un 50,1% de soluciones IM en las peores condiciones ( $N = 200$  y distribución 5D2). En estas condiciones, esta proporción se reduce considerablemente hasta un 32,7% ( $\lambda_{ij} = 0,4$ ) y hasta un 16,6% ( $\lambda_{ij} = 0,5$ ). Cuando los datos tienen una distribución más equilibrada (5D1) se obtiene un 35,7% de soluciones IM para  $\lambda_{ij} = 0,3$ , un 12,8% para  $\lambda_{ij} = 0,4$ , y un 2,4% para  $\lambda_{ij} = 0,5$  (en Anexos). Con datos dicotómicos se observan resultados muy similares en función de las distintas condiciones analizadas, salvo que la proporción de soluciones IM es sensiblemente mayor que la encontrada a partir de los análisis realizados sobre datos ordinales (ver Figura 19). Tomando nuevamente la condición  $N = 200$ , para la distribución más asimétrica (2D3) se pasa de un 52,5% para  $\lambda_{ij} = 0,3$ , a un 38,5% ( $\lambda_{ij} = 0,4$ ), y a un 21,2% ( $\lambda_{ij} = 0,5$ ). En la distribución más equilibrada (2D1) se pasa de un 49,9% para  $\lambda_{ij} = 0,3$ , a un 33,3% ( $\lambda_{ij} = 0,4$ ), y a un 14% ( $\lambda_{ij} = 0,5$ ).

Figura 18. Proporción de soluciones IM (datos ordinales: 5 categorías,  $n = 3$ )

$2(D) \times 3(\lambda_{ij}) \times 4(N) \times 1(n) \times 1(E) = 24$  condiciones experimentales.

Figura 19. Proporción de soluciones IM (datos dicotómicos,  $n = 3$ )



$2(D) \times 3(\lambda_{ij}) \times 4(N) \times 1(n) \times 1(E) = 24$  condiciones experimentales.

### 3.2.2. Modelo de independencia y calidad en la recuperación de parámetros

Al igual que en el ESTUDIO 1, se ha calculado mediante ANCOVA el tamaño del efecto que tiene el test  $\chi^2_{\text{Null}}$  sobre cada uno de los índices de ajuste teórico elaborados ( $C_j$ ,  $RMSD_j$ ,  $ARB_j$  y  $AMSE_j$ ), controlando el efecto del resto de variables relevantes que determinan las condiciones de aplicación simuladas (ver Tabla 3). Nuevamente, rechazar la  $H_0$  del modelo de independencia tiene un efecto mayor sobre  $C_j$  que en el resto de índices analizados (aunque descendiend progresivamente:  $\eta^2 = 0,035$  con datos continuos,  $\eta^2 = 0,024$  con datos ordinales y  $\eta^2 = 0,011$  con datos dicotómicos;  $\lambda_{ij} = 0,3$ ). Por tanto, se ha vuelto a seleccionar  $C_j$  como índice de ajuste teórico para informar de los resultados obtenidos en este apartado.

Tabla 3. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ ,  $RMSD_j$ ,  $ARB_j$  y  $AMSE_j$ )

Efectos principales			$C_j$		$RMSD_j$		$ARB_j$		$AMSE_j$	
			$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$
Ordinales	$\lambda_{ij} = 0,3$	$\chi^2_{\text{Null}}$	,000	,024	,000	,011	,000	,016	,000	,011
		$N$	,000	,031	,000	,116	,000	,100	,000	,116
		$n$	,000	,002	,000	,028	,000	,025	,000	,028
		$E$	,287	,000	,000	,000	,001	,000	,000	,000
Dicotómicos	$\lambda_{ij} = 0,3$	$\chi^2_{\text{Null}}$	,000	,011	,000	,003	,000	,005	,000	,003
		$N$	,000	,029	,000	,103	,000	,085	,000	,103
		$n$	,000	,001	,000	,008	,000	,006	,000	,008
		$E$	,870	,000	,026	,000	,119	,000	,026	,000

Nota: Para la elaboración de estos análisis se han considerado las mejores condiciones en términos de distribución de los datos (5D1 para datos ordinales y 2D1 para datos dicotómicos).

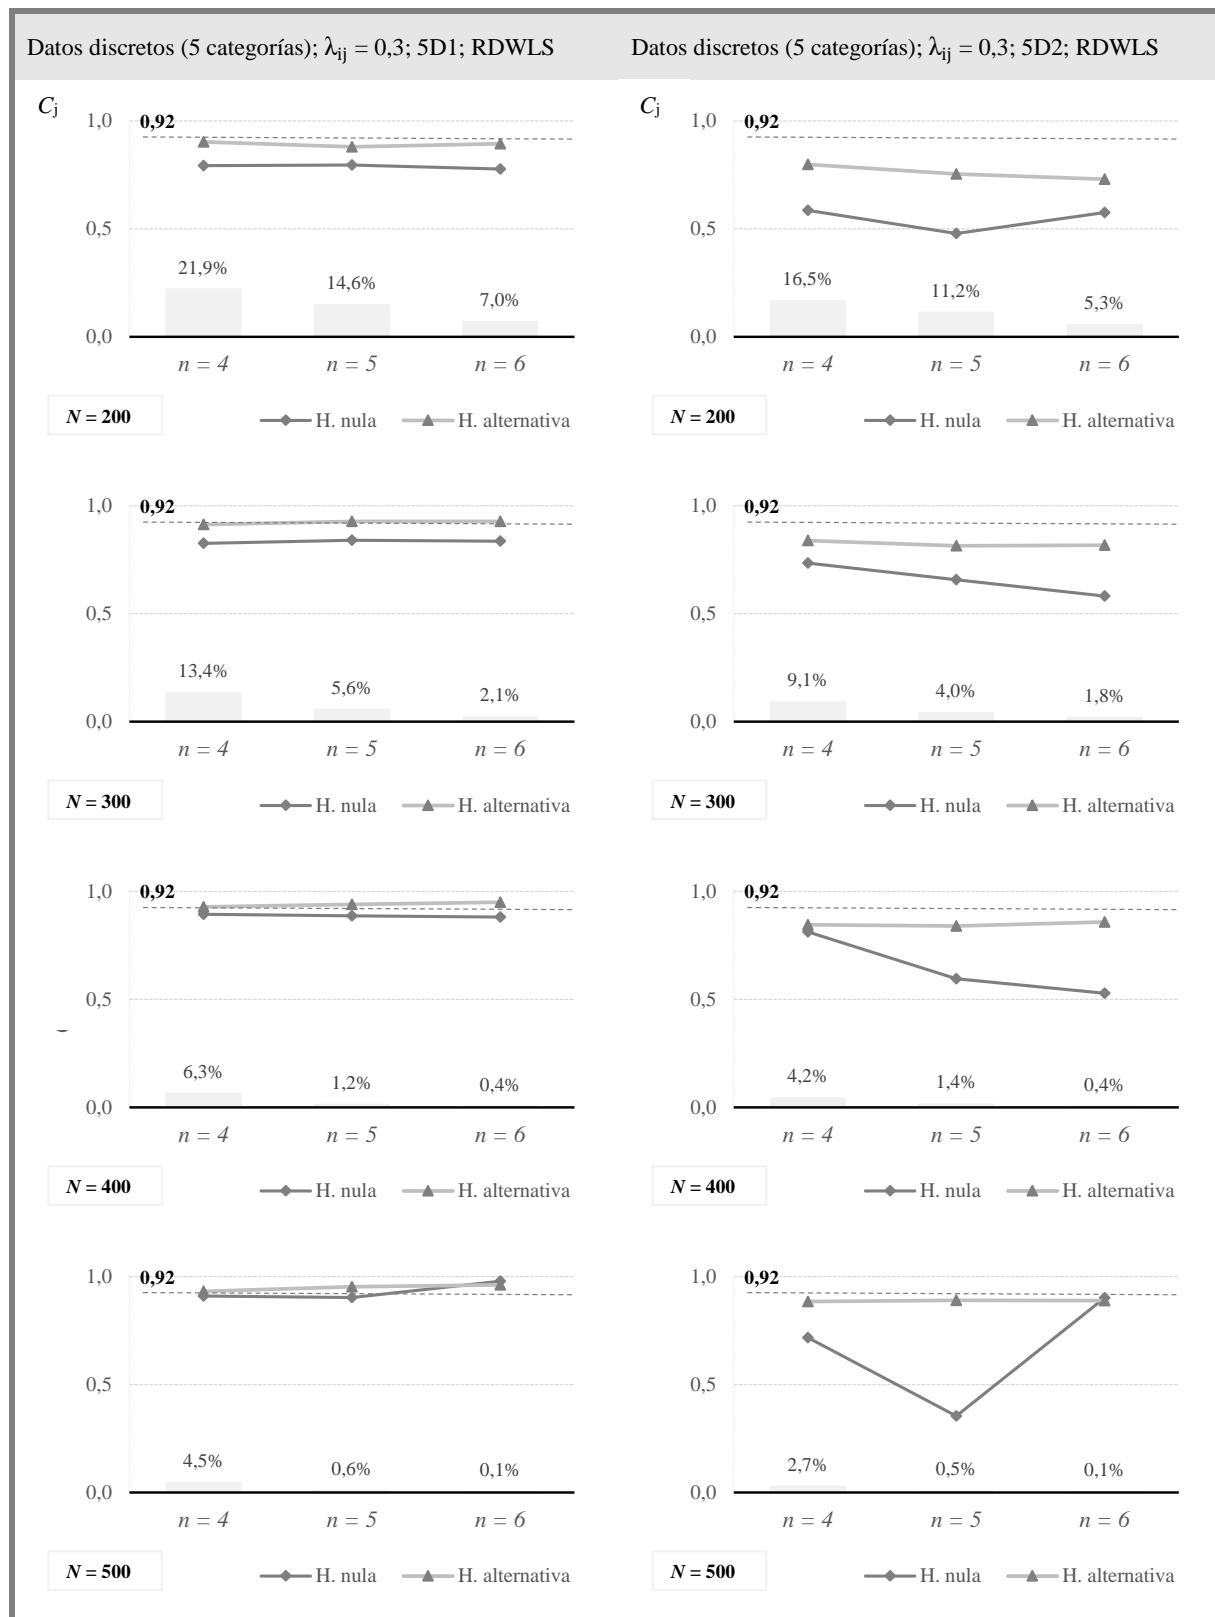
$\chi^2_{\text{Null}}$ : factor compuesto por dos niveles o grupos de comparación (T1 y T2).

Est.: método de estimación (RDWLS, RML, RULS).



Se comentan a continuación los resultados obtenidos para datos ordinales y dicotómicos (Figuras 20 y 21), tomando como condición de referencia la condición  $\lambda_{ij} = 0,3$ , y a partir de dos distribuciones distintas de los datos (5D1 y 5D2 con datos ordinales; 2D1 y 2D3 con datos dicotómicos). Se observan tendencias similares a las encontradas con datos continuos, con valores promedio de  $C_j$  superiores en la mayoría de soluciones T1. Mayores diferencias se observan al comparar entre distintos tipos de distribución de los datos, como señalan Forero et al. (2009). En las condiciones simuladas para datos ordinales (5D1), el ajuste teórico se encuentra en torno al valor recomendado en todas las condiciones, mientras que en las condiciones equivalentes simuladas para datos dicotómicos (2D1), este resultado se alcanza a partir de  $N = 400$  y  $n = 6$ . Por otro lado, al comparar las estimaciones realizadas en condiciones de asimetría (5D2 y 2D3) se observa un fuerte decremento del ajuste teórico. Solamente en los tamaños muestrales más elevados se obtienen valores de  $C_j$  próximos al valor recomendado.

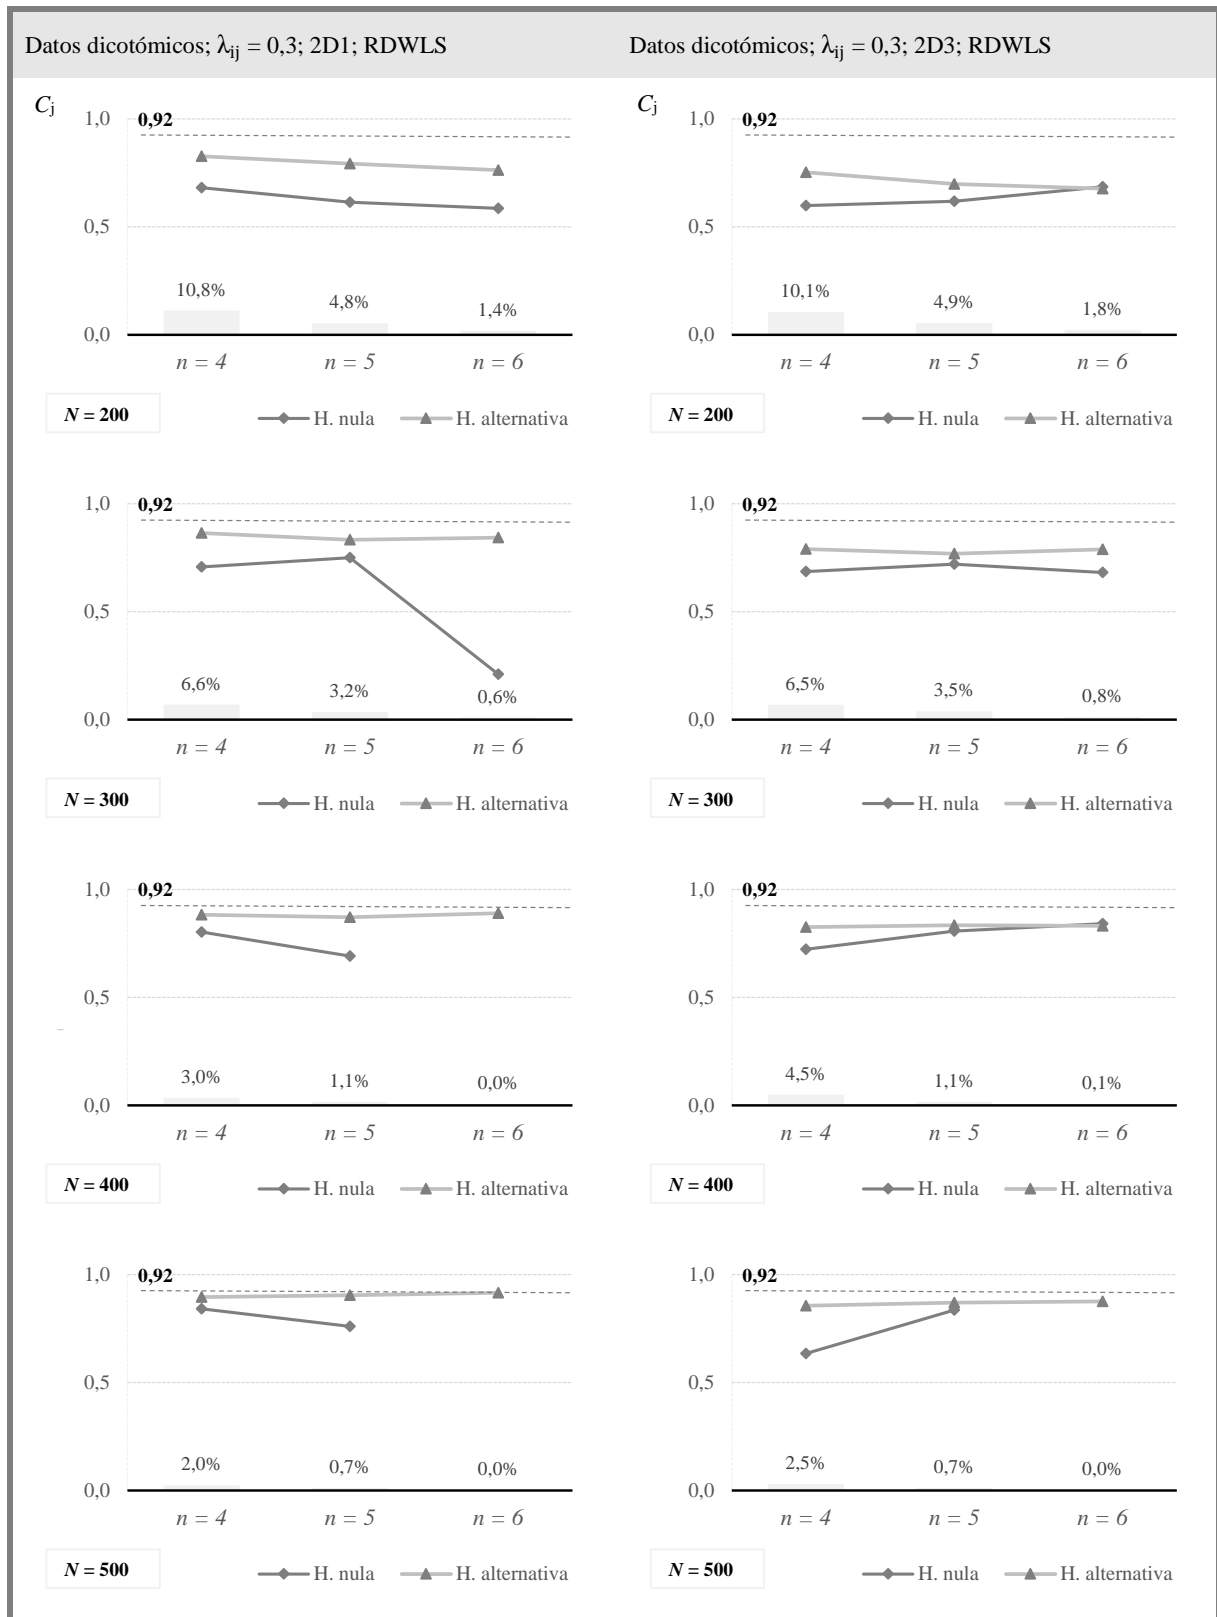
Conviene destacar que estos resultados, sumados al mayor número de soluciones IM, reflejan que los datos ordinales y dicotómicos (especialmente estos últimos) necesitan de condiciones más fuertes para que AFC tenga la suficiente sensibilidad para detectar factores VCL poblacionales. Como era esperable, esta situación se intensifica ante situaciones de asimetría. En comparación con los resultados que provienen del análisis de los datos continuos, se han intensificado las diferencias en la calidad de la recuperación entre las soluciones T1 y T2.

Figura 20. Promedio de  $C_j$  por tipo de solución (T1-T2). Datos ordinales; RDWLS

Se excluye la condición  $\lambda_{ij} = 0,4$  por acumular muy pocas soluciones T2 ( $H_0$  del modelo de independencia).

Las barras representan el porcentaje de soluciones T2.  $2(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 1(E) = 24$  condiciones experimentales. Estimación RDWLS.

Figura 21. Promedio de  $C_j$  por tipo de solución (T1-T2). Datos dicotómicos; RDWLS



Se excluye la condición  $\lambda_j = 0,4$  por acumular muy pocas soluciones T2 ( $H_0$  del modelo de independencia).

Las barras representan el porcentaje de soluciones T2.  $2(D) \times 1(\lambda_{ij}) \times 4(N) \times 3(n) \times 1(E) = 24$  condiciones experimentales. Estimación RDWLS.

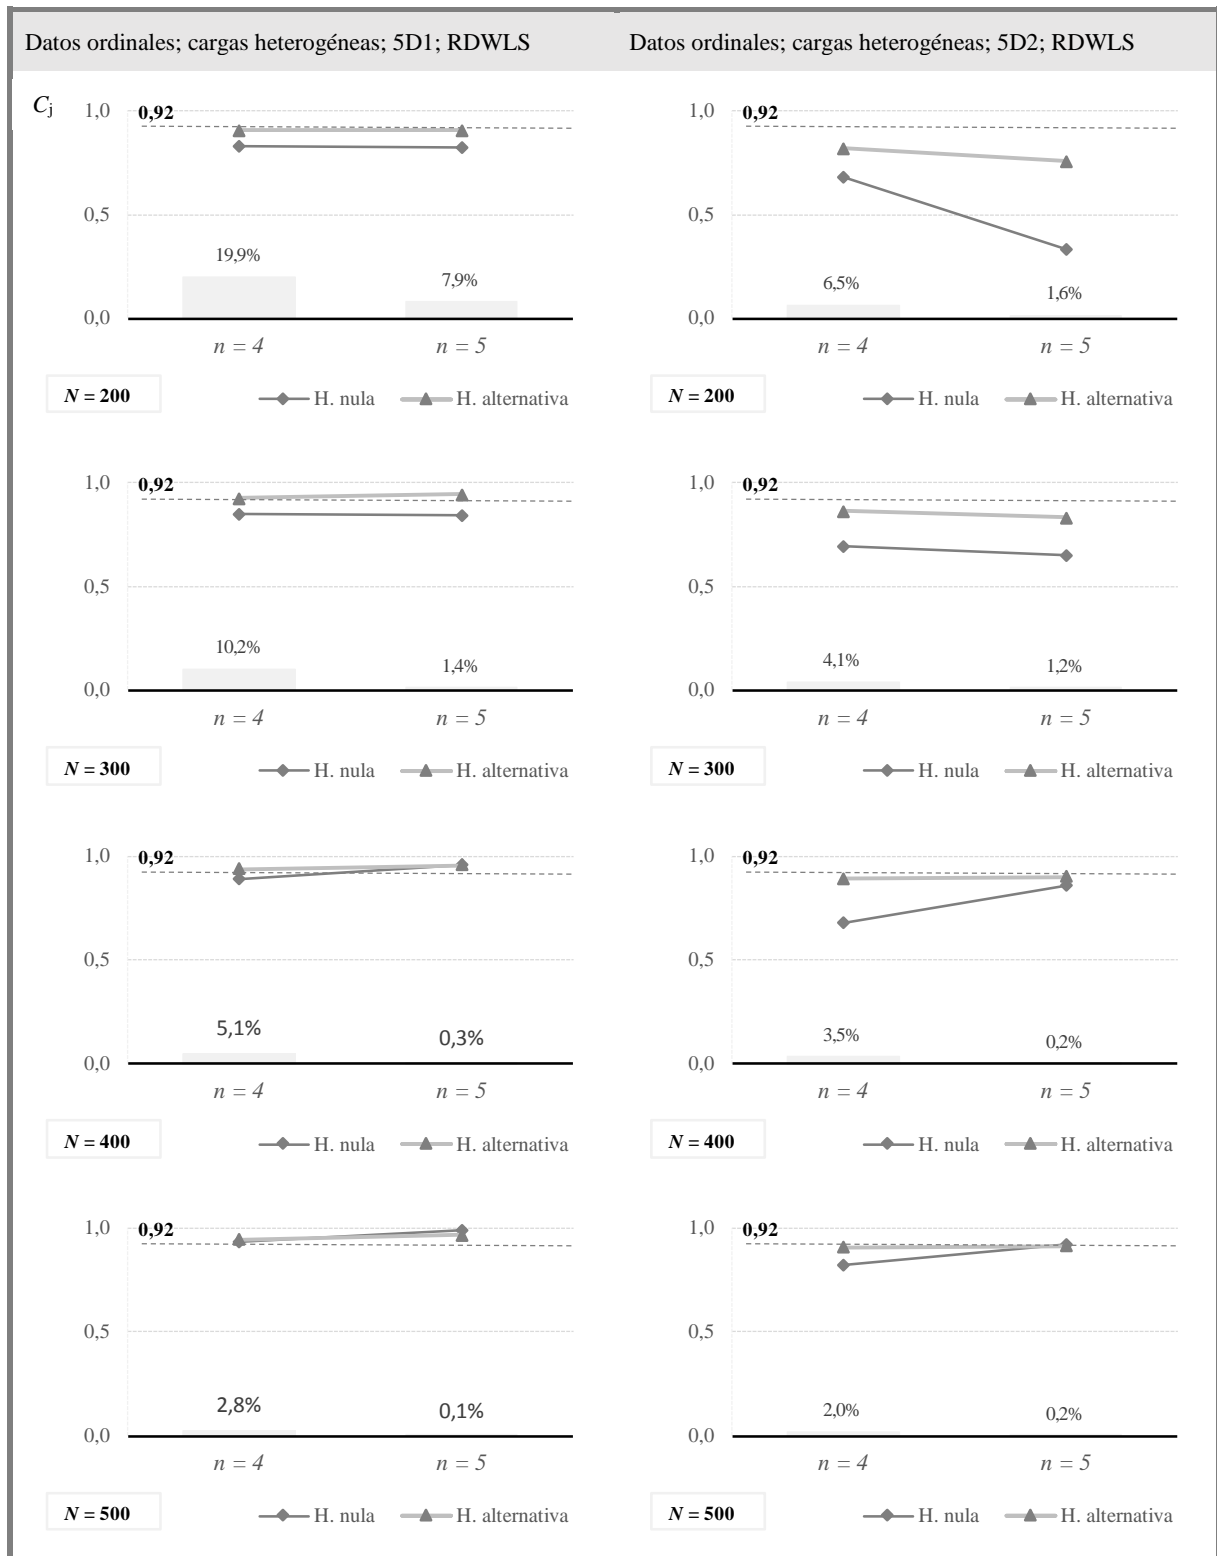
Los resultados del ANCOVA (efectos principales) que se muestran en la Tabla 4 reflejan nuevamente la conveniencia de utilizar  $C_j$  para simplificar la exposición de la recuperación de parámetros en condiciones simuladas a partir de cargas heterogéneas.

Tabla 4. Resultados de los ANCOVA (sin términos de interacción) para los índices de ajuste teórico ( $C_j$ ,  $RMSD_j$ ,  $ARB_j$  y  $AMSE_j$ ): niveles heterogéneos de lambda ( $\lambda_{Het.}$ ).

Efectos principales			$C_j$		$RMSD_j$		$ARB_j$		$AMSE_j$	
			$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$	$p$	$\eta^2$
5 cat.	$\lambda_{Het.}$ RDWLS (5D1)	$\chi^2_{Null}$	,000	,030	,000	,012	,000	,017	,000	,003
		$N$	,000	,043	,000	,105	,000	,102	,000	,112
		$n$	,000	,005	,000	,031	,000	,030	,005	,001
5 cat.	$\lambda_{Het.}$ RDWLS (5D2)	$\chi^2_{Null}$	,000	,017	,000	,004	,000	,006	,002	,002
		$N$	,000	,042	,000	,110	,000	,101	,000	,121
		$n$	,002	,002	,000	,003	,000	,003	,000	,009
Dicot.	$\lambda_{Het.}$ RDWLS (2D1)	$\chi^2_{Null}$	,000	,013	,000	,002	,000	,005	,647	,000
		$N$	,000	,032	,000	,097	,000	,090	,000	,104
		$n$	,937	,000	,000	,012	,000	,011	,000	,003
Dicot.	$\lambda_{Het.}$ RDWLS (2D3)	$\chi^2_{Null}$	,000	,014	,000	,004	,000	,006	,031	,001
		$N$	,000	,031	,000	,090	,000	,085	,000	,105
		$n$	,025	,001	,000	,003	,000	,002	,000	,008

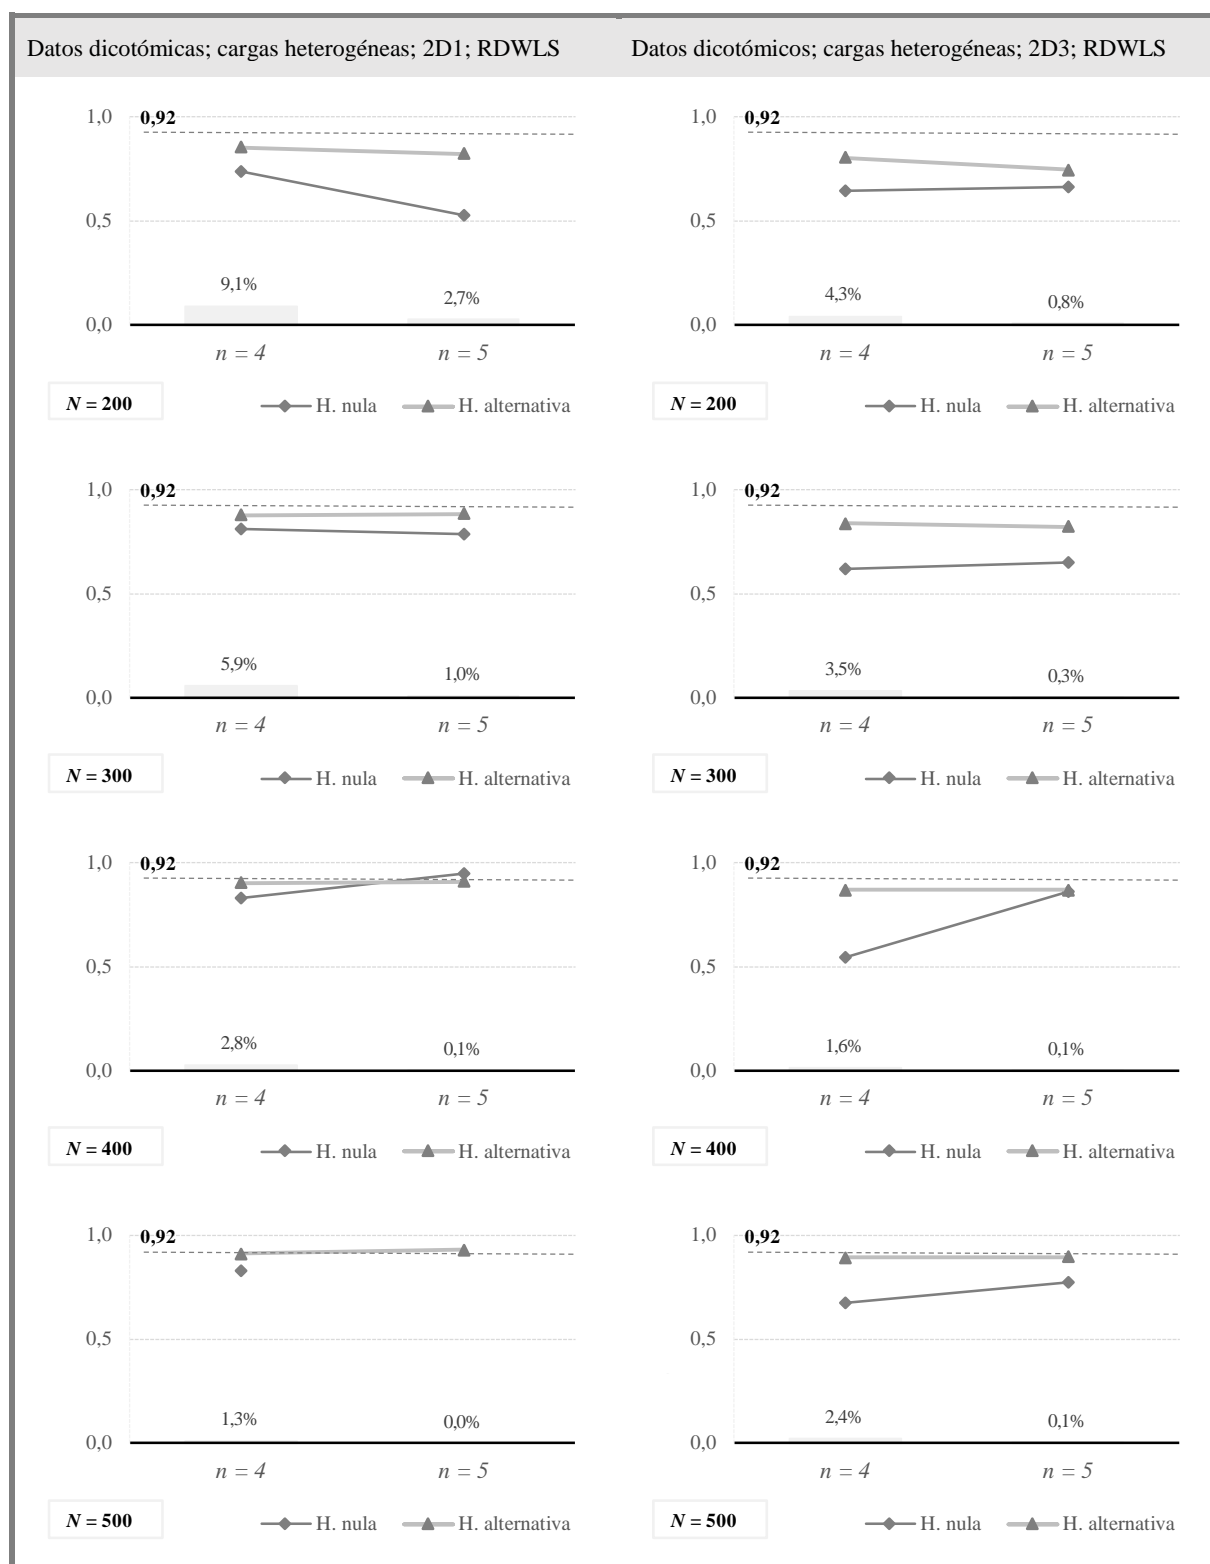
En las condiciones simuladas más simétricas (5D1 y 2D1) se observa que las discrepancias entre los parámetros simulados y estimados son muy similares al comparar las soluciones T1 y T2 (Figuras 22 y 23), igual que ocurría con datos continuos. No obstante, en estas condiciones se necesita de un tamaño muestral más elevado para llegar a los mismos resultados obtenidos en el ESTUDIO 1. En otras palabras, con datos continuos la recuperación de parámetros es muy similar en las soluciones T1 y T2 desde  $N = 200$ , mientras que con datos ordinales y dicotómicos esta situación empieza a manifestarse a partir de  $N = 400$ . En las condiciones más asimétricas (5D2 y 2D3), las diferencias de ajuste teórico entre las soluciones T1 y T2 son mayores.

Figura 22. Promedio de  $C_j$  por tipo de solución (T1-T2). Datos ordinales;  $\lambda_{ij}$  heterogéneas; RDWLS



Las barras representan el porcentaje de soluciones T2.

$2(D) \times 1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 16$  condiciones experimentales. Estimación RDWLS.

Figura 23. Promedio de  $C_j$  por tipo de solución (T1-T2). Datos dicotómicos;  $\lambda_{ij}$  heterogéneas; RDWLS

Las barras representan el porcentaje de soluciones T2.

$2(D) \times 1(\lambda_{ij}) \times 4(N) \times 2(n) \times 1(E) = 16$  condiciones experimentales. Estimación RDWLS.

Con el fin de potenciar la comparabilidad de los resultados obtenidos, en las Tablas 5 y 6 se resume toda la información correspondiente a la proporción de soluciones IM, T1 y T2, y a la calidad en la recuperación de parámetros tanto para los análisis que se derivan de datos continuos (ESTUDIO 1) como los que se derivan de datos ordinales y dicotómicos (ESTUDIO 2). Las soluciones utilizadas para elaborar estas tablas son las que se obtuvieron a partir de ML y de RDWLS. En resumen, en factores simulados con 4 cargas fijas en 0,3 (Tabla 5) y datos continuos se obtiene una proporción de soluciones T1 del 87,9% ( $N = 400$ ) y del 93,9% ( $N = 500$ ), con valores promedio de ajuste teórico ( $C_j$ ) por encima del valor recomendado (0,92). La proporción de soluciones T1 y el nivel de ajuste teórico son muy similares con datos ordinales y distribución simétrica (5D1), pero descienden en el caso asimétrico (5D2), con un 80,2% de soluciones T1 y un valor promedio de  $C_j = 0,88$  ( $N = 500$ ).

Frente a estos resultados, la proporción de soluciones T1 disminuye al analizar datos dicotómicos, sin llegar a obtenerse ningún promedio de ajuste teórico que se encuentre por encima del valor recomendado. Todos estos resultados mejoran sensiblemente en los factores simulados a partir de 5 cargas fijadas a 0,3. No obstante, solamente se obtienen valores promedio de ajuste teórico por encima del valor recomendado con datos continuos y ordinales (5D1), igual que ocurría en la condición  $n = 4$ . En factores simulados con 4 cargas heterogéneas (condición  $\lambda_{ij}$  (0,15-0,45), ver Tabla 6) se obtienen resultados similares a los anteriores. La principal diferencia que se observa es que, con cargas heterogéneas, aumenta el número de soluciones IM aunque disminuye el número de soluciones T2. Al final, la proporción de soluciones T1 es similar en ambos tipos de condiciones, si bien mejora ligeramente el ajuste teórico de este tipo de soluciones cuando se simulan cargas heterogéneas. Lo mismo puede observarse en la condición  $n = 5$  ( $\lambda_{ij}$  (0,1-0,5)).

Tabla 5. Comparación de la proporción de soluciones IM, T1 y T2 y del valor promedio de  $C_j$  en función de los datos simulados: nivel fijo de  $\lambda_{ij} = 0,3$

Datos	N	n = 4					n = 5				
		IM	T2: H <sub>0</sub> mod. indep.	T1: H <sub>1</sub> mod. indep.	IM	T2: H <sub>0</sub> mod. indep.	T1: H <sub>1</sub> mod. indep.	IM	T2: H <sub>0</sub> mod. indep.	T1: H <sub>1</sub> mod. indep.	
		%	%	C <sub>j</sub> (D.T.)	%	C <sub>j</sub> (D.T.)	%	%	C <sub>j</sub> (D.T.)	%	C <sub>j</sub> (D.T.)
Continuos	200	17,9%	28,5%	,85 (.22)	53,6%	,92 (.12)	8,2%	20,2%	,83 (.24)	71,6%	,91 (.15)
	300	8,8%	15,0%	,88 (.10)	76,2%	,93 (.06)	1,9%	7,9%	,90 (.07)	90,2%	,94 (.07)
	400	3,6%	8,5%	,91 (.08)	87,9%	,94 (.05)	0,9%	2,1%	,84 (.35)	97,0%	,95 (.04)
	500	1,6%	4,5%	,92 (.07)	93,9%	,95 (.05)	0,4%	0,6%	,88 (.12)	99,0%	,96 (.03)
Ordinales (5D1)	200	19,7%	21,9%	,79 (.32)	58,4%	,90 (.15)	7,8%	14,6%	,80 (.22)	77,6%	,88 (.22)
	300	10,8%	13,4%	,83 (.22)	75,8%	,91 (.13)	2,5%	5,6%	,84 (.16)	91,9%	,93 (.08)
	400	5,9%	6,3%	,89 (.08)	87,8%	,93 (.09)	1,4%	1,2%	,89 (.07)	97,4%	,94 (.09)
	500	2,2%	4,5%	,91 (.06)	93,3%	,93 (.13)	0,3%	0,6%	,90 (.09)	99,1%	,95 (.07)
Ordinales (5D2)	200	40,3%	16,5%	,59 (.45)	43,2%	,80 (.32)	25,6%	11,2%	,48 (.54)	63,2%	,75 (.39)
	300	33,8%	9,1%	,74 (.35)	57,1%	,84 (.27)	16,5%	4,0%	,66 (.37)	79,5%	,81 (.32)
	400	22,7%	4,2%	,81 (.23)	73,1%	,85 (.27)	9,6%	1,4%	,60 (.50)	89,0%	,84 (.30)
	500	17,1%	2,7%	,72 (.44)	80,2%	,88 (.17)	7,3%	0,5%	,35 (.63)	92,2%	,89 (.21)
Dicotómicos (2D1)	200	35,7%	10,8%	,68 (.35)	53,5%	,83 (.27)	23,9%	4,8%	,61 (.41)	71,3%	,79 (.32)
	300	27,9%	6,6%	,71 (.32)	65,5%	,86 (.21)	13,0%	3,2%	,75 (.19)	83,8%	,83 (.29)
	400	20,7%	3,0%	,80 (.18)	76,3%	,88 (.18)	8,4%	1,1%	,69 (.42)	90,5%	,87 (.23)
	500	14,4%	2,0%	,84 (.11)	83,6%	,90 (.16)	4,4%	0,7%	,76 (.14)	94,9%	,90 (.15)
Dicotómicos (2D3)	200	40,2%	10,1%	,60 (.49)	49,7%	,75 (.35)	34,9%	4,9%	,62 (.43)	60,2%	,70 (.43)
	300	36,2%	6,5%	,69 (.45)	57,3%	,79 (.34)	21,1%	3,5%	,72 (.39)	75,4%	,77 (.38)
	400	28,9%	4,5%	,72 (.40)	66,6%	,83 (.29)	15,9%	1,1%	,81 (.20)	83,0%	,83 (.29)
	500	22,8%	2,5%	,63 (.54)	74,7%	,86 (.24)	11,8%	0,7%	,84 (.20)	87,5%	,87 (.21)

Estimación ML (datos continuos) y estimación RDWLS (datos ordinales y dicotómicos).

El aumento de soluciones IM no es accidental. Es cierto que la estimación de cargas más elevadas a nivel poblacional potencia el rechazo estadístico del modelo de independencia al tiempo que mejora la calidad de la recuperación. No obstante, la estimación de cargas poblacionales entre 0,1 y 0,2 facilita la aparición de problemas de convergencia y la estimación de valores aberrantes, lo que debe ser interpretado como una merma en la sensibilidad o potencia estadística de la prueba.



Tabla 6. Comparación de la proporción de soluciones IM, T1 y T2 y del valor promedio de  $C_j$  en función de los datos simulados: cargas heterogéneas

Datos	N	$n = 4 (\lambda_{ij} (0,15-0,45))$					$n = 5 (\lambda_{ij} (0,1-0,5))$				
		IM	T2: $H_0$ mod. indep.	T1: $H_1$ mod. indep.			IM	T2: $H_0$ mod. indep.	T1: $H_1$ mod. indep.		
		%	%	$C_j$ (D.T.)	%	$C_j$ (D.T.)	%	%	$C_j$ (D.T.)	%	$C_j$ (D.T.)
Continuos	200	21,1%	24,4%	,90 (.09)	54,5%	,93 (.06)	9,9%	9,4%	,91 (.07)	80,7%	,94 (.06)
	300	13,6%	11,3%	,91 (.08)	75,1%	,94 (.06)	3,5%	2,0%	,94 (.05)	94,5%	,96 (.04)
	400	7,0%	5,3%	,93 (.05)	87,7%	,95 (.05)	1,7%	0,3%	,91 (.12)	98,0%	,97 (.03)
	500	4,2%	2,2%	,93 (.06)	93,6%	,96 (.04)	0,9%	0,0%	---	99,1%	,97 (.03)
Ordinales (5D1)	200	21,5%	19,9%	,83 (.18)	58,6%	,91 (.11)	9,8%	7,9%	,82 (.26)	82,3%	,90 (.17)
	300	14,9%	10,2%	,85 (.13)	74,9%	,93 (.07)	4,0%	1,4%	,84 (.12)	94,6%	,94 (.07)
	400	10,4%	5,1%	,89 (.10)	84,5%	,94 (.06)	2,2%	0,3%	,96 (.02)	97,5%	,96 (.04)
	500	6,1%	2,8%	,93 (.06)	91,1%	,95 (.05)	1,4%	0,1%	---	98,5%	,97 (.03)
Ordinales (5D2)	200	44,5%	6,5%	,68 (.29)	49,0%	,82 (.23)	30,3%	1,6%	,33 (.53)	68,1%	,76 (.39)
	300	35,6%	4,1%	,69 (.35)	60,3%	,86 (.15)	20,2%	1,2%	,65 (.44)	78,6%	,83 (.31)
	400	28,4%	3,5%	,68 (.37)	68,1%	,89 (.12)	12,9%	0,2%	,86 (.02)	86,9%	,90 (.17)
	500	21,6%	2,0%	,82 (.17)	76,4%	,91 (.08)	10,5%	0,2%	,92 (.04)	89,3%	,91 (.18)
Dicotómicos (2D1)	200	39,7%	9,1%	,74 (.28)	51,2%	,85 (.18)	22,7%	2,7%	,53 (.58)	74,6%	,82 (.30)
	300	29,5%	5,9%	,81 (.17)	64,6%	,88 (.12)	15,1%	1,0%	,79 (.22)	83,9%	,88 (.20)
	400	24,0%	2,8%	,83 (.15)	73,2%	,90 (.09)	9,5%	0,1%	---	90,4%	,91 (.16)
	500	17,8%	1,3%	,83 (.13)	80,9%	,91 (.09)	8,1%	0,0%	---	91,9%	,93 (.12)
Dicotómicos (2D3)	200	44,9%	4,3%	,64 (.34)	50,8%	,80 (.24)	34,7%	0,8%	,66 (.25)	64,5%	,74 (.39)
	300	37,3%	3,5%	,62 (.31)	59,2%	,84 (.21)	24,4%	0,3%	,65 (.23)	75,3%	,82 (.31)
	400	33,3%	1,6%	,54 (.44)	65,1%	,87 (.16)	17,8%	0,1%	---	82,1%	,87 (.23)
	500	28,0%	2,4%	,67 (.38)	69,6%	,89 (.13)	13,2%	0,1%	---	86,7%	,89 (.19)

Estimación ML (datos continuos) y estimación RDWLS (datos ordinales y dicotómicos).

Por último, se resumen a continuación los resultados obtenidos en la evaluación del ajuste teórico cuando se evalúan factores compuestos por tres variables observables (condición  $n = 3$ ). Como se comentó en el Capítulo 2, estos modelos están exactamente identificados, por lo que no es posible obtener valores ni índices fruto del proceso de estimación, como el valor  $\chi^2_{\text{Null}}$ . Por lo tanto, no se muestran los porcentajes asociados a las soluciones T1 y T2. Se han escogido los cuatro índices de ajuste teórico para la exposición de los resultados (ver Figuras 24 y 25), aunque la interpretación se ha realizado nuevamente a partir de  $C_j$ .

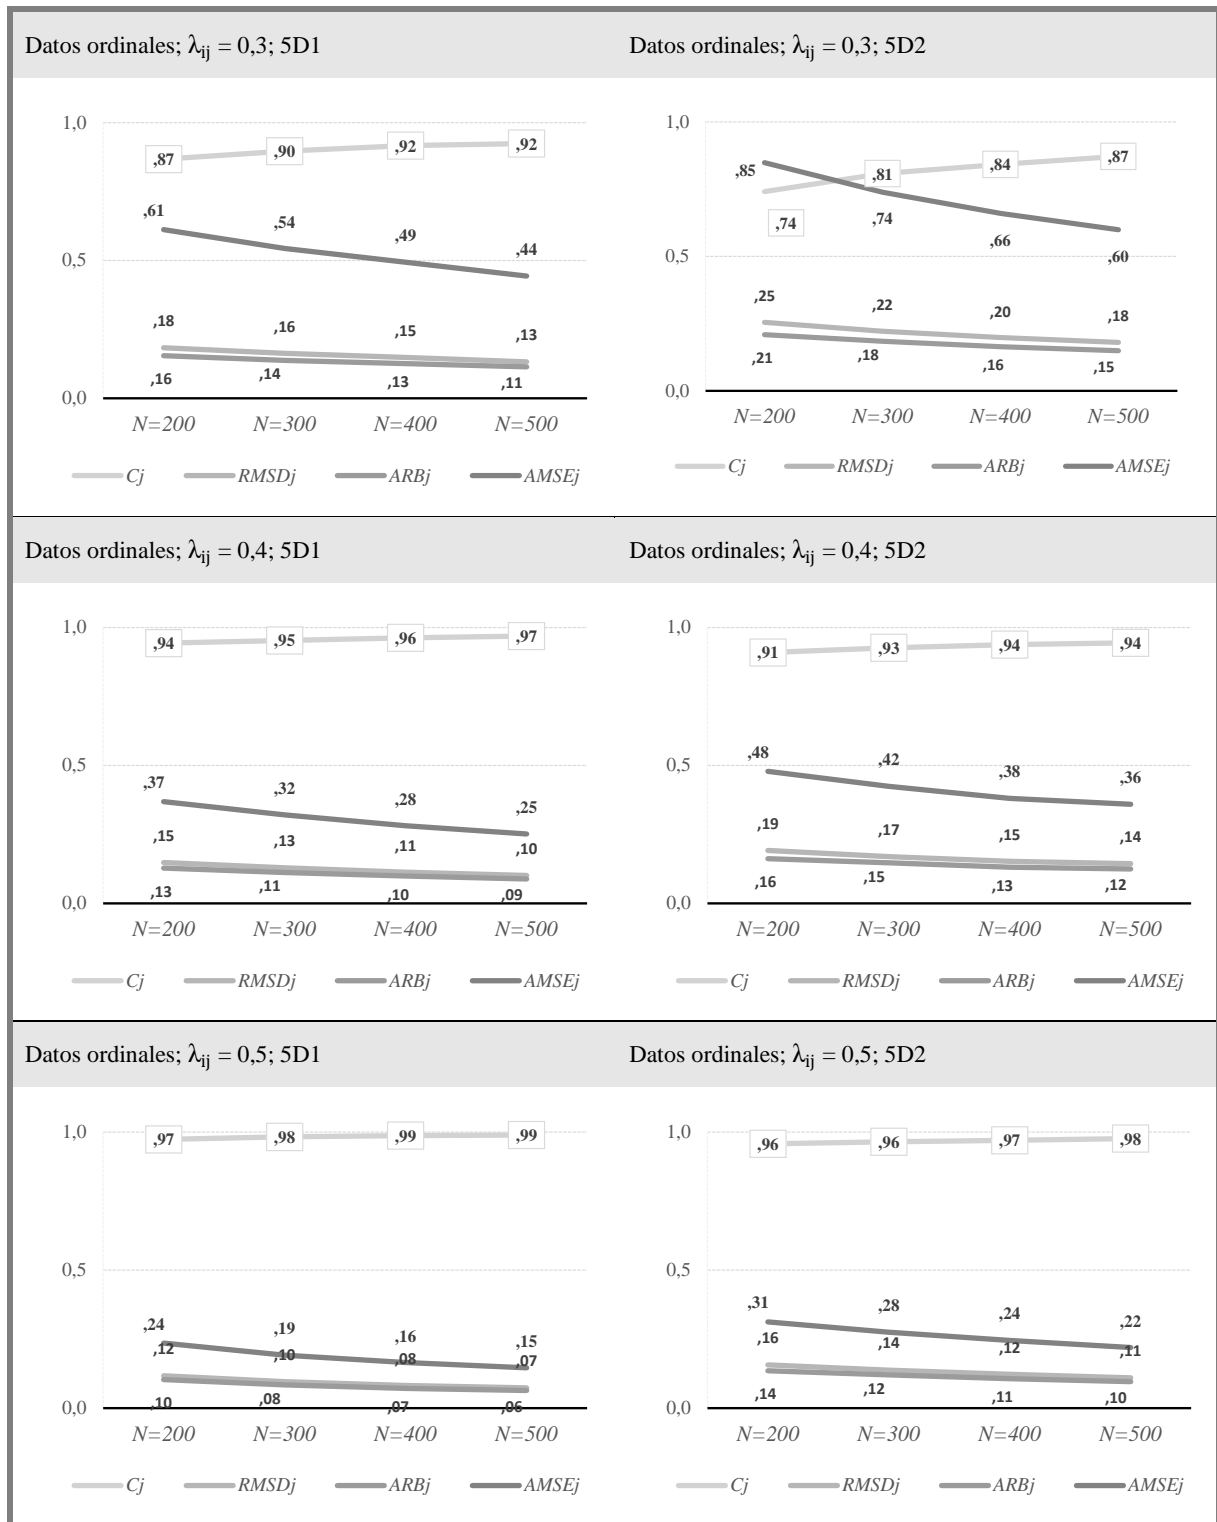
Para datos ordinales (Figura 24) con  $\lambda_{ij} = 0,3$  y distribución simétrica (5D1), se obtienen valores promedio de  $C_j$  en torno al valor recomendado (0,92) a partir de  $N = 400$ . Con una

variable observable más ( $n = 4$ ) se obtienen valores promedio de  $C_j$  adecuados a partir de  $N = 200$  (ver Figura 21). Cuando los datos presentan asimetría (5D2), el ajuste teórico promedio no alcanza el valor recomendado ni siquiera en la condición  $N = 500$  (con  $n = 4$  se obtenían valores promedio de  $C_j$  próximos a 0,92 con 500 observaciones). Con valores simulados  $\lambda_{ij} = 0,4$  el promedio de  $C_j$  se encuentra por encima del valor recomendado a partir de  $N = 200$  en condiciones de simetría (5D1), y a partir de  $N = 300$  en condiciones de asimetría (5D2;  $\lambda_{ij} = 0,4$ ).

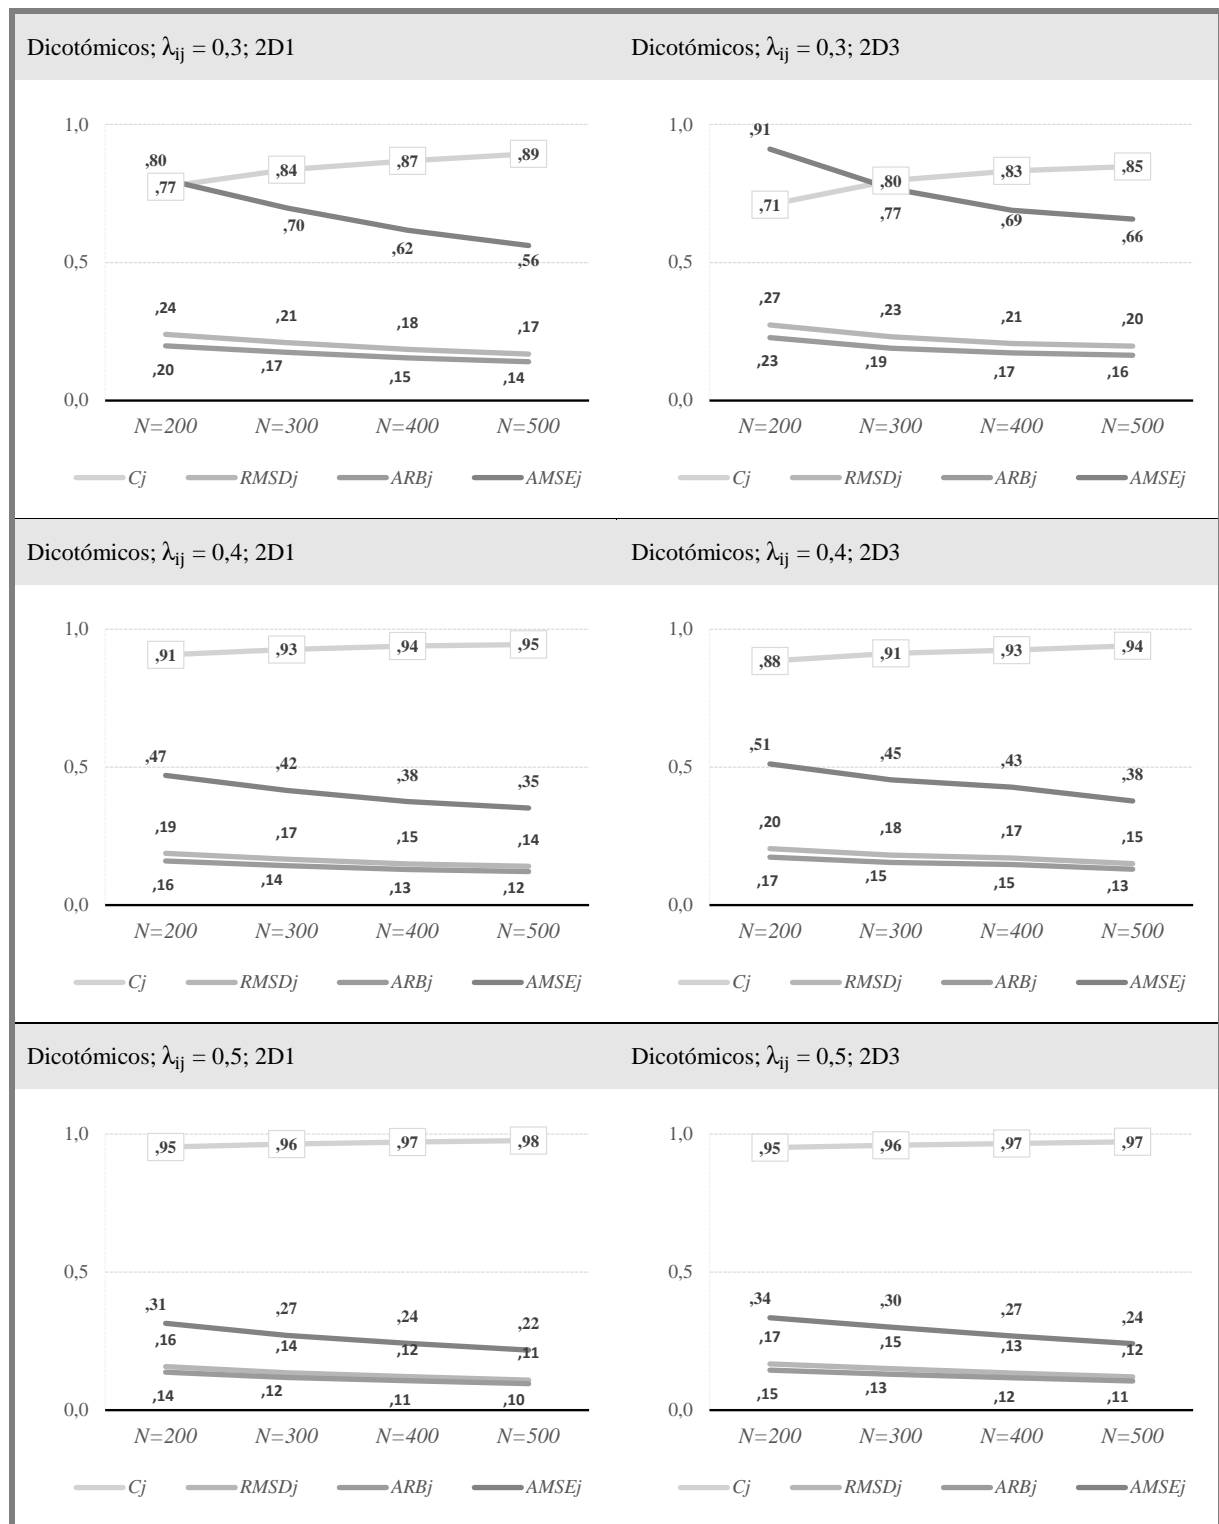
Con datos dicotómicos (Figura 25), la condición  $\lambda_{ij} = 0,3$  obtiene discrepancias en la recuperación de parámetros demasiado elevadas, incluso en la distribución 50% - 50% (2D1) y con tamaños muestrales elevados (esta situación mejora nuevamente en la condición  $n = 4$ , aunque tampoco se sobrepasa el valor 0,92 con  $N = 500$ ; ver Figura 22). Para obtener promedios de  $C_j$  por encima del valor recomendado en la condición  $\lambda_{ij} = 0,4$  se requiere de 300 a 400 observaciones (para las distribuciones 5D1 y 5D2, respectivamente). La condición  $\lambda_{ij} = 0,5$  obtiene en todas las condiciones simuladas valores de ajuste teórico adecuados, tanto en los análisis realizados a partir de datos ordinales como en los realizados a partir de datos dicotómicos.

Si comparamos los resultados anteriores en la condición  $\lambda_{ij} = 0,3$  en la evaluación de factores con 4 variables observables ( $n = 4$ ) y 500 observaciones se obtenían promedios de  $C_j$  en torno al valor recomendado  $C_j \geq 0,92$ .

Figura 24. Promedio de los índices de ajuste teórico en la condición  $n = 3$ . Datos ordinales



$2(D) \times 3(\lambda_{ij}) \times 4(N) \times 1(n) \times 1(E) = 24$  condiciones experimentales.

Figura 25. Promedio de los índices de ajuste teórico en la condición  $n = 3$ . Datos dicotómicos

$2(D) \times 3(\lambda_{ij}) \times 4(N) \times 1(n) \times 1(E) = 24$  condiciones experimentales.

### 3.2.3. Modelo de independencia e índices descriptivos de ajuste

Las tendencias analizadas en el ESTUDIO 1 sobre los índices descriptivos de ajuste son extrapolables al caso ordinal y al caso dicotómico. En resumen, en este tipo de datos encontramos nuevamente una clara falta de sensibilidad de  $\chi^2_0$ , RMSEA y SRMR para diferenciar entre soluciones T1 y T2, además de oscilar dentro de los puntos de corte indicativos de ajuste que se recomiendan habitualmente. NNFI obtiene valores fuera de rango muy frecuentemente, en especial en las soluciones T2, y CFI plantea problemas parciales de sensibilidad al indicar valores de ajuste en T2 en determinadas condiciones. Nuevamente, ECVI, AIC y CAIC reflejan una clara capacidad para diferenciar soluciones T1 y T2.

Como se comentó en la introducción del apartado 3.1.3, se ha realizado una comparación adicional a la mostrada hasta ahora (diferencias entre soluciones T1 y T2), en relación al comportamiento de los índices descriptivos evaluados respecto al nivel de ajuste teórico en las soluciones T1, y que se expone a continuación. La motivación para realizar esta comparación adicional es la de profundizar en la sensibilidad de todos estos índices para identificar no solamente soluciones T1, sino soluciones con un adecuado ajuste teórico. Esta cuestión ha sido abordada en este apartado con el fin de resaltar la relevancia de los resultados cuando se trabaja con ítems. Recordemos que el investigador aplicado desconoce por regla general el valor de los parámetros poblacionales, por lo que no está en disposición de calcular el grado de ajuste teórico de los modelos evaluados. Esta comparación entre soluciones con mayor o menor nivel de ajuste teórico dentro del conjunto de soluciones T1 está orientada a elaborar un conjunto de recomendaciones que permitan paliar este desconocimiento del valor de los parámetros poblacionales en escenarios aplicados, como la utilización de ECVI como medida de aproximación.

Para realizar este tipo de comparaciones se han descartado  $\chi^2_0$ , RMSEA y SRMR por su falta de sensibilidad, NNFI por la frecuente presencia de valores fuera de rango y AIC<sub>r</sub> por su elevada similitud respecto a ECVI<sub>r</sub>. Por tanto, se analizan los índices CFI, ECVI<sub>r</sub> y CAIC<sub>r</sub>. Para obtener estos resultados se ha calculado el porcentaje de soluciones sobre el total simulado que se pueden clasificar dentro de cada nivel de ajuste teórico (columna %), siguiendo los puntos de corte descritos en el Capítulo 2. Se han analizado solamente aquellas condiciones en las que se simularon factores con 4 y 5 variables observables, para optimizar la comparación respecto a las condiciones simuladas a partir de cargas heterogéneas y que, a su vez, reflejan condiciones frecuentes en la práctica. Se analizan de forma agregada los cuatro tamaños muestrales simulados. Los resultados obtenidos en el resto de condiciones pueden inspeccionarse en Anexos. En las Tablas 7 y 8 ( $n = 4$  y  $n = 5$ , respectivamente) se muestra el valor promedio (desviación típica entre paréntesis) de los tres índices evaluados en relación a su grado de ajuste teórico dentro del conjunto de soluciones en las que se ha rechazado la  $H_0$  del modelo de independencia, y en función de la tipología de datos analizada (incluyendo los resultados del ESTUDIO 1 y del ESTUDIO 2 para potenciar su comparación).

En términos generales, los resultados indican un mejor comportamiento de los índices a medida que se obtienen estimaciones menos discrepantes con los parámetros poblacionales. Además, el ajuste teórico es más elevado cuando se trabaja con datos continuos, con un 17,4% de soluciones que presentan una recuperación excelente. Con datos ordinales este porcentaje desciende hasta un 13,3%, y con datos dicotómicos hasta un 7,1% cuando las distribuciones son simétricas (5D1 y 2D1), y hasta un 5,5% y un 5% en condiciones de asimetría (5D2 y 2D3, respectivamente). Con datos continuos, CFI obtiene valores dentro de lo recomendado (aproximadamente) independientemente del nivel de ajuste teórico de las soluciones, situación que se intensifica con datos ordinales y dicotómicos. Por tanto, no parece que CFI sea un índice

de utilidad para discriminar entre soluciones con mayor o menor calidad en la recuperación, una vez rechazado estadísticamente el modelo de independencia.

Tabla 7. Estadísticos descriptivos de los índices CFI, ECVI<sub>r</sub> y CAIC<sub>r</sub> dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Nivel fijo de  $\lambda_{ij} = 0,3$ ,  $n = 4$

Datos y distribución	Índices	$C_j (n = 4)$							
		%	Inestable	%	Límite	%	Aceptable	%	Excelente
<i>Continuos (ML)</i>	CFI		0,95 (0,09)		0,96 (0,08)		0,97 (0,06)		0,98 (0,05)
	ECVI <sub>r</sub>	3,5%	1,50 (0,29)	16,1%	1,65 (0,41)	40,9%	1,89 (0,54)	17,4%	2,09 (0,61)
	CAIC <sub>r</sub>		0,84 (0,09)		0,89 (0,13)		0,96 (0,17)		1,02 (0,19)
<i>Ordinales (RDWLS)</i>	5D1		0,96 (0,08)		0,97 (0,07)		0,98 (0,06)		0,98 (0,04)
	ECVI <sub>r</sub>	6,1%	1,61 (0,39)	20,3%	1,76 (0,46)	39,2%	2,01 (0,61)	13,3%	2,28 (0,71)
	CAIC <sub>r</sub>		0,87 (0,13)		0,92 (0,15)		1,00 (0,19)		1,08 (0,22)
	5D2		0,95 (0,10)		0,98 (0,05)		0,98 (0,05)		0,98 (0,07)
	ECVI <sub>r</sub>	13,7%	1,73 (0,48)	21,2%	1,97 (0,56)	23,1%	2,18 (0,67)	5,5%	2,23 (0,77)
	CAIC <sub>r</sub>		0,91 (0,15)		0,98 (0,18)		1,05 (0,21)		1,06 (0,24)
	5D3		0,96 (0,10)		0,96 (0,08)		0,98 (0,06)		0,98 (0,05)
	ECVI <sub>r</sub>	5,9%	1,63 (0,42)	20,2%	1,77 (0,49)	38,6%	2,01 (0,62)	14,1%	2,21 (0,70)
	CAIC <sub>r</sub>		0,89 (0,13)		0,93 (0,15)		1,00 (0,19)		1,06 (0,22)
<i>Dicotómicos (RDWLS)</i>	2D1		0,99 (0,03)		0,99 (0,03)		0,99 (0,03)		0,99 (0,03)
	ECVI <sub>r</sub>	12,8%	1,94 (0,62)	24,0%	2,33 (0,88)	25,9%	2,65 (1,00)	7,1%	2,79 (1,00)
	CAIC <sub>r</sub>		0,98 (0,20)		1,11 (0,28)		1,21 (0,32)		1,25 (0,31)
	2D2		0,98 (0,05)		0,99 (0,04)		0,98 (0,04)		0,99 (0,02)
	ECVI <sub>r</sub>	14,3%	2,02 (0,68)	23,8%	2,37 (0,91)	25,7%	2,60 (0,98)	6,1%	2,83 (1,05)
	CAIC <sub>r</sub>		1,01 (0,22)		1,12 (0,29)		1,19 (0,31)		1,26 (0,33)
	2D3		0,99 (0,04)		0,98 (0,04)		0,98 (0,04)		0,99 (0,02)
	ECVI <sub>r</sub>	16,0%	2,16 (0,82)	21,6%	2,43 (0,89)	19,6%	2,49 (1,03)	5,0%	2,65 (1,09)
	CAIC <sub>r</sub>		1,05 (0,26)		1,14 (0,29)		1,15 (0,32)		1,20 (0,34)

*Datos ordinales:* 5D1: 1 (5%), 2 (20%), 3 (50%), 4 (20%) y 5 (5%); 5D2: 1 (5%), 2 (5%), 3 (5%), 4 (10%) y 5 (75%); 5D3: 1 (20%), 2 (20%), 3 (20%), 4 (20%) y 5 (20%).

*Datos dicotómicos:* 2D1: 0 (50%), 1 (50%); 2D2: 0 (40%), 1 (60%); 2D3: 0 (75%), 1 (25%).

*Ajuste teórico:* Inestable ( $C_j < 0,82$ ); Límite ( $0,82 \geq C_j < 0,92$ ); Aceptable ( $0,92 \geq C_j \leq 0,98$ ); Excelente ( $C_j > 0,98$ ).

Por otro lado, los valores de ECVI<sub>r</sub> y CAIC<sub>r</sub> crecen más rápidamente a medida que mejora el ajuste teórico, si bien conviene señalar el aumento de la desviación típica de dichos valores en las soluciones con mayor grado de ajuste teórico. Se observan las mismas tendencias a partir de los análisis realizados sobre datos ordinales y dicotómicos, aunque mejora su

comportamiento en condiciones de mayor asimetría. Esta mejoría no debe ser interpretada directamente ya que cuando se analizan los datos discretos en condiciones de asimetría (especialmente los dicotómicos) se produce un mayor número de soluciones IM. Siguiendo este razonamiento, varias soluciones estimadas a partir de datos continuos con ajuste teórico pobre, no serían estimables con datos discretos y en condiciones de asimetría, produciendo soluciones IM, lo que afectaría al resultado de los tres índices analizados a nivel promedio (CFI,  $ECVI_r$  y  $CAIC_r$ ). En otras palabras, en estas condiciones solo “pasarían las mejores soluciones”, de ahí las diferencias en magnitud de los tres índices analizados. Como se comentó anteriormente, la sensibilidad del AFC cuando se aplica a datos en condiciones de asimetría necesita ser compensada o potenciada mediante otras condiciones (mayor número de variables observables y/o mayor tamaño muestral), especialmente con datos ordinales y dicotómicos. Las principales diferencias entre los resultados obtenidos a partir de  $n = 4$  y de  $n = 5$  es que en la segunda condición se obtiene una mayor proporción de soluciones con niveles aceptables o superiores de ajuste teórico, y que el valor de los índices  $ECVI_r$  y  $CAIC_r$  obtienen valores promedio mayores. Los valores de CFI obtienen valores muy similares en la condición  $n = 4$  y  $n = 5$ . Dichos valores se encuentran muy próximos al valor máximo, por lo que podría decirse que se produce un cierto efecto techo en estas condiciones.

No es misión de este trabajo presentar puntos de corte alternativos a los de CFI para utilizar  $ECVI_r$  y  $CAIC_r$  como indicadores de ajuste teórico en contextos aplicados. Nuestro objetivo es mostrar cómo la utilización de estos índices puede aumentar las evidencias de consistencia empírica del investigador aplicado sobre los modelos evaluados ante el desconocimiento generalizado de los parámetros poblacionales. Una ventaja que ofrecen los índices  $ECVI_r$  y  $CAIC_r$  es el marcado incremento que se produce en sus valores cuando se obtienen soluciones con buen ajuste teórico, además de ser sensibles a la sobreparametrización



(como se mostró en apartados anteriores). Por tanto, obtener valores claramente más elevados de ECVI y de CAIC aplicados sobre el modelo de independencia que sobre el modelo evaluado ofrece mayores garantías al investigador aplicado sobre la calidad y precisión de la estimación de parámetros.

Tabla 8. Estadísticos descriptivos de los índices CFI, ECVI<sub>r</sub> y CAIC<sub>r</sub> dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Nivel fijo de  $\lambda_{ij} = 0,3$ ,  $n = 5$

Datos y distribución	Índices	$C_j (n = 5)$							
		%	Inestable	%	Límite	%	Aceptable	%	Excelente
<i>Continuos (ML)</i>	CFI		0,90 (0,13)		0,94 (0,09)		0,96 (0,07)		0,97 (0,05)
	ECVI <sub>r</sub>	2,3%	1,43 (0,26)	15,4%	1,59 (0,37)	51,1%	1,96 (0,55)	20,7%	2,26 (0,64)
	CAIC <sub>r</sub>		0,85 (0,09)		0,90 (0,13)		1,02 (0,18)		1,12 (0,21)
<i>Ordinales (RDWLS)</i>	5D1		0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
			0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
			0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
	5D2		0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
			0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
			0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
	5D3		0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
			0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
			0,93 (0,10)		0,96 (0,07)		0,97 (0,06)		0,97 (0,05)
<i>Dicotómicos (RDWLS)</i>	2D1		0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
			0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
			0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
	2D2		0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
			0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
			0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
	2D3		0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
			0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)
			0,99 (0,03)		0,98 (0,03)		0,99 (0,03)		0,98 (0,03)

*Datos ordinales:* 5D1: 1 (5%), 2 (20%), 3 (50%), 4 (20%) y 5 (5%); 5D2: 1 (5%), 2 (5%), 3 (5%), 4 (10%) y 5 (75%); 5D3: 1 (20%), 2 (20%), 3 (20%), 4 (20%) y 5 (20%).

*Datos dicotómicos:* 2D1: 0 (50%), 1 (50%); 2D2: 0 (40%), 1 (60%); 2D3: 0 (75%), 1 (25%).

*Ajuste teórico:* Inestable ( $C_j < 0,82$ ); Límite ( $0,82 \geq C_j < 0,92$ ); Aceptable ( $0,92 \geq C_j \leq 0,98$ ); Excelente ( $C_j > 0,98$ ).

Curiosamente, de los tres índices analizados solamente CFI utiliza  $\chi^2_{\text{Null}}$  en su formulación, si bien no parece ser muy sensible a situaciones en las que el valor de este estadístico es reducido, mostrando una mayor sensibilidad para detectar situaciones de infraparametrización. Tal vez su sensibilidad para pre-evaluar clústers independientes sea más efectiva en estructuras con mayor número de variables observables, ya que en estas condiciones el valor de  $\chi^2_{\text{Null}}$  tiende a crecer considerablemente.

Por último, en las Tablas 9 y 10 se muestra el comportamiento de los tres índices analizados en los modelos simulados a partir de cargas factoriales heterogéneas ( $n = 4$  y  $n = 5$ , respectivamente).

Tabla 9. Estadísticos descriptivos de los índices CFI, ECVI<sub>r</sub> y CAIC<sub>r</sub> dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Cargas heterogéneas ( $n = 4$ )

Datos y distribución	Índices	$C_j \ (n = 4: \lambda_{ij} \ (0,15-0,45))$								
		%	Inestable	%	Límite	%	Aceptable	%	Excelente	
<i>Continuos (ML)</i>	CFI		0,95 (0,08)		0,96 (0,08)		0,97 (0,06)		0,97 (0,06)	
	ECVI <sub>r</sub>	2,6%	1,50 (0,33)	14,5%	1,74 (0,46)	41,3%	1,97 (0,57)	19,4%	2,09 (0,62)	
	CAIC <sub>r</sub>		0,84 (0,11)		0,91 (0,14)		0,98 (0,18)		1,02 (0,19)	
<i>Ordinales (RDWLS)</i>	5D1	CFI		0,95 (0,09)		0,97 (0,06)		0,98 (0,05)		0,98 (0,04)
		ECVI <sub>r</sub>	4,5%	1,51 (0,34)	18,0%	1,87 (0,56)	39,6%	2,10 (0,63)	15,3%	2,21 (0,66)
		CAIC <sub>r</sub>		0,85 (0,11)		0,96 (0,18)		1,03 (0,19)		1,06 (0,20)
	5D2	CFI		0,99 (0,03)		0,99 (0,03)		0,99 (0,03)		0,99 (0,02)
		ECVI <sub>r</sub>	12,4%	2,12 (0,73)	21,1%	2,43 (0,83)	23,4%	2,81 (1,02)	6,6%	3,04 (1,15)
		CAIC <sub>r</sub>		1,04 (0,23)		1,14 (0,27)		1,25 (0,32)		1,33 (0,36)
<i>Dicotóm. (RDWLS)</i>	2D1	CFI		0,99 (0,03)		0,99 (0,03)		0,99 (0,02)		0,99 (0,03)
		ECVI <sub>r</sub>	12,0%	2,08 (0,66)	21,5%	2,36 (0,86)	26,5%	2,66 (0,98)	7,5%	2,87 (1,03)
		CAIC <sub>r</sub>		1,03 (0,21)		1,12 (0,27)		1,21 (0,32)		1,27 (0,33)
	2D3	CFI		0,99 (0,02)		0,99 (0,02)		0,99 (0,02)		0,99 (0,02)
		ECVI <sub>r</sub>	14,3%	2,26 (0,80)	20,4%	2,75 (0,97)	21,0%	3,01 (1,12)	5,6%	3,14 (1,13)
		CAIC <sub>r</sub>		1,09 (0,26)		1,24 (0,31)		1,32 (0,35)		1,37 (0,36)

*Datos ordinales:* 5D1: 1 (5%), 2 (20%), 3 (50%), 4 (20%) y 5 (5%); 5D2: 1 (5%), 2 (5%), 3 (5%), 4 (10%) y 5 (75%); 5D3: 1 (20%), 2 (20%), 3 (20%), 4 (20%) y 5 (20%).

*Datos dicotómicos:* 2D1: 0 (50%), 1 (50%); 2D2: 0 (40%), 1 (60%); 2D3: 0 (75%), 1 (25%).

*Ajuste teórico:* Inestable ( $C_j < 0,82$ ); Límite ( $0,82 \geq C_j < 0,92$ ); Aceptable ( $0,92 \geq C_j \leq 0,98$ ); Excelente ( $C_j > 0,98$ ).

Como puede observarse, las tendencias son muy similares a las mostradas en las Tablas 7 y 8. En estas condiciones, el ajuste teórico muestra una ligera mejoría respecto a las condiciones simuladas a partir de las condiciones con cargas fijadas en 0,3, si bien conviene recordar que en las condiciones simuladas a partir de cargas heterogéneas existe un mayor número de soluciones IM. El aumento del número de soluciones con ajuste teórico se refleja de forma más clara en la condición  $n = 5$  ( $\lambda_{ij}$  (0,1-0,5)), especialmente con datos continuos y datos ordinales (5D1). Esta situación se produce a pesar de que los factores simulados presentan una carga poblacional de 0,1 y otra de 0,2.

Tabla 10. Estadísticos descriptivos de los índices CFI, ECVI<sub>r</sub> y CAIC<sub>r</sub> dentro de las soluciones T1 en función de distintos niveles de ajuste teórico. Cargas heterogéneas ( $n = 5$ )

Datos y distribución	Índices	$C_j$ ( $n = 5$ : $\lambda_{ij}$ (0,1-0,5))							
		%	Inestable	%	Límite	%	Aceptable	%	Excelente
<i>Continuos (ML)</i>	CFI		0,88 (0,16)		0,95 (0,08)		0,97 (0,06)		0,97 (0,05)
	ECVI <sub>r</sub>	1,1%	1,43 (0,37)	8,8%	1,69 (0,41)	49,0%	2,15 (0,62)	34,2%	2,45 (0,70)
	CAIC <sub>r</sub>		0,86 (0,13)		0,94 (0,14)		1,09 (0,20)		1,19 (0,23)
<i>Ordinales (RDWLS)</i>	5D1		0,90 (0,13)		0,96 (0,07)		0,97 (0,05)		0,98 (0,04)
			ECVI <sub>r</sub>	2,8%	1,51 (0,32)	14,2%	1,86 (0,52)	52,1%	2,33 (0,69)
			CAIC <sub>r</sub>		0,89 (0,12)		1,16 (0,23)		1,25 (0,25)
	5D2		0,98 (0,04)		0,99 (0,03)		0,99 (0,02)		0,99 (0,02)
			ECVI <sub>r</sub>	12,5%	2,24 (0,66)	24,1%	2,76 (0,86)	36,3%	3,15 (1,00)
			CAIC <sub>r</sub>		1,14 (0,24)		1,31 (0,30)		1,44 (0,34)
<i>Dicotóm. (RDWLS)</i>	2D1		0,98 (0,04)		0,99 (0,03)		0,99 (0,03)		0,98 (0,03)
			ECVI <sub>r</sub>	9,4%	2,07 (0,56)	24,6%	2,54 (0,80)	42,0%	2,98 (0,92)
			CAIC <sub>r</sub>		1,08 (0,20)		1,24 (0,27)		1,38 (0,31)
	2D3		0,99 (0,02)		0,99 (0,02)		0,99 (0,02)		0,99 (0,02)
			ECVI <sub>r</sub>	15,4%	2,49 (0,81)	25,3%	3,08 (1,01)	31,2%	3,51 (1,10)
			CAIC <sub>r</sub>		1,23 (0,29)		1,42 (0,34)		1,57 (0,37)

*Datos ordinales:* 5D1: 1 (5%), 2 (20%), 3 (50%), 4 (20%) y 5 (5%); 5D2: 1 (5%), 2 (5%), 3 (5%), 4 (10%) y 5 (75%); 5D3: 1 (20%), 2 (20%), 3 (20%), 4 (20%) y 5 (20%).

*Datos dicotómicos:* 2D1: 0 (50%), 1 (50%); 2D2: 0 (40%), 1 (60%); 2D3: 0 (75%), 1 (25%).

*Ajuste teórico:* Inestable ( $C_j < 0,82$ ); Límite ( $0,82 \geq C_j < 0,92$ ); Aceptable ( $0,92 \geq C_j \leq 0,98$ ); Excelente ( $C_j > 0,98$ ).

### 3.3. Aproximación a los estudios de potencia

En el presente apartado se detallan los resultados obtenidos tras realizar un estudio de potencia con los datos disponibles tras el proceso de estimación de parámetros en las condiciones simuladas. Este tipo de estudios abordan la cuestión del Error Tipo II (Brown, 2015; Muthén y Muthén, 2002), y podrían ser complementarios al proceso de pre-evaluación expuesto en este trabajo. Ambas estrategias de análisis permiten evaluar hasta qué punto ciertas condiciones de aplicación son suficientes para que el AFC sea capaz de estimar parámetros poblacionales con precisión. En otras palabras, en ambos casos lo que se pretende es valorar hasta qué punto AFC es una herramienta sensible para detectar parámetros poblacionales. En el caso de los estudios de potencia, generalmente el interés se centra en evaluar la potencia del AFC en determinadas condiciones para estimar con precisión parámetros concretos. Estos estudios se suelen realizar sobre modelos multidimensionales. En el caso de la pre-evaluación del modelo de independencia el interés se centra no tanto en el parámetro particular sino en la variable latente como unidad, asumiendo la necesidad de realizar este tipo de evaluaciones en condiciones *subóptimas*. Una cuestión que se ha tratado de abordar en el presente apartado es si a partir de ambas estrategias de análisis se obtienen resultados convergentes y, por tanto, se puede llegar a unas recomendaciones unificadas sobre las condiciones de aplicación.

A continuación, se muestran los resultados obtenidos tras aplicar la lógica de los estudios de potencia con la información generada en el presente trabajo, diferenciando nuevamente entre soluciones T1 y T2. Para cada tipo de solución se muestra el valor promedio entre réplicas muestrales de  $\hat{\lambda}_{ij}$  (en la columna *Mean*), su desviación típica (*S.D.*), y el error estándar promedio (*S.E. average*). Para calcular el porcentaje de sesgo en la estimación de cada parámetro (*Param. bias (%)*) se aplica la expresión  $((Mean - \lambda_{ij}) / \lambda_{ij}) \times 100$ , y para calcular el porcentaje de sesgo

del error estándar (*S.E. bias (%)*) se aplica la expresión  $((S.E. average - S.D.)/S.D.) \times 100$ . A diferencia de *Param. bias (%)*, en donde el parámetro poblacional es conocido ( $\lambda_{ij}$ ), para calcular *S.E. bias (%)* se utiliza el valor promedio de las desviaciones típicas (*S.D.*) como valor poblacional del error estándar.

Las tablas siguientes también ofrecen el porcentaje de soluciones o réplicas en las que el parámetro es estadísticamente distinto de cero con  $\alpha = 0,05$  (columna *% Sig. Coeff.*). Para ello, en primer lugar se dividió el valor de cada carga factorial estimada por su error estándar, y se clasificó en cada réplica si el valor resultante se encontraba fuera del rango  $\pm 1,96$  ya que el ratio parámetro/*S.E.* puede interpretarse como una puntuación *z* (Brown, 2015). El porcentaje de réplicas en las que los parámetros son estadísticamente significativos es la información en la que se fundamenta este apartado. Más concretamente, se utiliza dicha información como medida de potencia, siguiendo el punto de corte propuesto por Cohen del 80%. Por simplicidad, se han seleccionado solamente las tablas que se han considerado más representativas.

En la Tabla 11 se muestran los resultados obtenidos para datos continuos, en condiciones simuladas a partir de 4 cargas fijadas en 0,3 (estimación ML). Puede observarse que en las soluciones T2 ( $H_0$  del modelo de independencia), el valor promedio de los parámetros estimados es siempre inferior al parámetro poblacional (0,3), y que el porcentaje de parámetros estadísticamente distintos de cero a través de todas las réplicas muestrales (*% Sig. Coeff.*) se encuentra claramente por debajo del valor de potencia recomendado (80%). Por el contrario, en las soluciones T1 se observa una mayor aproximación de los parámetros estimados al valor poblacional, aunque con tendencia a la sobreestimación. Estas diferencias en los valores promedio de los parámetros estimados entre las soluciones T1 y T2 ya se comentó en apartados anteriores, y puede consultarse en el Anexo F.

Tabla 11. Resultados obtenidos en relación a los estudios de potencia con datos continuos. Nivel fijo de  $\lambda_{ij}$  ( $\lambda_{ij} = 0,3$ ),  $n = 4$ , estimación ML

$x_i$	$N$	$H_0$ modelo independencia (T2)						$H_1$ modelo independencia (T1)					
		Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.	Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.
$x_1$	200	0,276	0,147	0,208	-7,8%	41,2%	14,7%	0,350	0,156	0,152	16,6%	-2,6%	70,9%
	300	0,261	0,150	0,194	-13,1%	29,8%	16,7%	0,325	0,140	0,133	8,3%	-5,3%	76,6%
	400	0,239	0,108	0,150	-20,3%	39,1%	28,2%	<b>0,317</b>	<b>0,121</b>	<b>0,114</b>	<b>5,8%</b>	<b>-5,7%</b>	<b>86,7%</b>
	500	0,260	0,121	0,156	-13,4%	29,2%	37,8%	<b>0,311</b>	<b>0,108</b>	<b>0,101</b>	<b>3,7%</b>	<b>-6,0%</b>	<b>91,2%</b>
$x_2$	200	0,258	0,197	0,220	-13,9%	11,7%	12,6%	0,339	0,156	0,146	12,8%	-5,9%	72,2%
	300	0,265	0,158	0,197	-11,6%	25,0%	20,0%	0,316	0,132	0,126	5,3%	-4,9%	76,1%
	400	0,256	0,162	0,195	-14,6%	20,8%	22,4%	<b>0,308</b>	<b>0,120</b>	<b>0,111</b>	<b>2,6%</b>	<b>-8,1%</b>	<b>84,9%</b>
	500	0,218	0,133	0,139	-27,2%	5,0%	31,1%	<b>0,305</b>	<b>0,104</b>	<b>0,100</b>	<b>1,8%</b>	<b>-4,0%</b>	<b>90,1%</b>
$x_3$	200	0,268	0,183	0,217	-10,7%	18,9%	13,3%	0,336	0,168	0,146	11,8%	-12,7%	69,2%
	300	0,250	0,142	0,181	-16,7%	27,1%	22,0%	0,321	0,131	0,130	6,9%	-0,5%	78,1%
	400	0,229	0,112	0,145	-23,7%	28,7%	24,7%	<b>0,312</b>	<b>0,113</b>	<b>0,111</b>	<b>4,1%</b>	<b>-2,0%</b>	<b>87,5%</b>
	500	0,230	0,096	0,131	-23,5%	36,4%	31,1%	<b>0,306</b>	<b>0,102</b>	<b>0,100</b>	<b>2,1%</b>	<b>-2,5%</b>	<b>91,3%</b>
$x_4$	200	0,264	0,182	0,214	-12,0%	17,1%	13,3%	0,349	0,156	0,150	16,2%	-3,8%	72,6%
	300	0,255	0,168	0,181	-15,0%	7,6%	22,7%	<b>0,332</b>	<b>0,135</b>	<b>0,132</b>	<b>10,6%</b>	<b>-1,9%</b>	<b>80,8%</b>
	400	0,254	0,118	0,161	-15,3%	36,2%	27,1%	<b>0,320</b>	<b>0,120</b>	<b>0,114</b>	<b>6,6%</b>	<b>-5,4%</b>	<b>85,4%</b>
	500	0,247	0,108	0,142	-17,8%	31,5%	33,3%	<b>0,313</b>	<b>0,110</b>	<b>0,102</b>	<b>4,4%</b>	<b>-6,7%</b>	<b>90,8%</b>

A partir de 400 observaciones los resultados indican que los parámetros son estadísticamente distintos de cero en más del 80% de las réplicas. Estos resultados son consistentes con los obtenidos a partir de la pre-evaluación del modelo de independencia, ya que es en estas condiciones ( $\lambda_{ij} = 0,3$ ,  $n = 3$  y  $N = 400$ ) en las que se rechaza  $H_0$  (prueba  $\chi^2_{\text{Null}}$ ) en más de un 80% de las soluciones. Más concretamente, se estima un 87,9% de soluciones T1, con un porcentaje de soluciones IM del 3,6% (ver Tabla 5 del apartado 3.2.2). En estas mismas condiciones pero con una variable observable más ( $n = 5$ ), el estudio de potencia refleja valores por encima del 80% en la estimación de parámetros a partir de  $N = 300$  (en la Tabla 5 del apartado 3.2.2 se indica un 90,2% de soluciones T1 y un 1,9% de soluciones IM). Con datos continuos,  $\lambda_{ij} = 0,2$ ,  $n = 15$  y  $N = 500$  se obtienen valores adecuados de potencia en

aproximadamente la mitad de las variables observables. Con  $\lambda_{ij} = 0,4$  la estimación de parámetros muestra valores de potencia por encima del 80% incluso con  $n = 4$  y  $N = 200$ .

En las condiciones en las que se han simulado cargas heterogéneas a partir de datos continuos se observan con facilidad valores de potencia por encima del 80% en las estimación de las cargas simuladas entre 0,3 y 0,5, mientras que en la estimación de las cargas simuladas 0,2 y 0,25 solamente se obtienen valores de potencia en la condición  $N = 500$ . La estimación de las cargas simuladas 0,1 y 0,15 no tienen la potencia suficiente en ninguna de las condiciones evaluadas (ver Tablas 12 y 13).

La comparación de estos resultados con la pre-evaluación del modelo de independencia no es tan directa como cuando se valoran los resultados que provienen de la simulación a partir de cargas factoriales fijas. Los resultados de la pre-evaluación (ver Tabla 6) indican que en la condición  $n = 4$ :  $\lambda_{ij}$  (0,15-0,45) con  $N = 400$  se rechaza el modelo de independencia en el 87,7% de las soluciones (soluciones T1), con un 7% de soluciones IM. El estudio de potencia indica que, en las mismas condiciones, solamente obtienen valores de potencia  $> 80\%$  los parámetros estimados para las variables observables  $x_1$  y  $x_2$  ( $\lambda_{ij} = 0,45$  y  $\lambda_{ij} = 0,35$ , respectivamente, ver Tabla 12). Esta disparidad de resultados se debe a la lógica seguida en la estrategia de pre-evaluación propuesta mediante  $\chi^2_{Null}$ , la cual difiere respecto a los estudios de potencia en que evalúa el factor completo, no cada uno de sus parámetros individuales. Expresado de otra forma, la pre-evaluación de factores simulados con cargas heterogéneas funciona como una prueba de sensibilidad en función del valor promedio de las cargas estimadas, de ahí la necesidad de complementar ambos tipos de estudios.

Tablas 12 y 13. Resultados obtenidos en relación a los estudios de potencia con datos continuos. Cargas heterogéneas, estimación ML

Tabla 12.  $n = 4$  (entre paréntesis el valor poblacional de lambda para cada  $x_i$ )

$x_i$	$N$	$H_0$ modelo independencia (T2)						$H_1$ modelo independencia (T1)					
		Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.	Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.
$x_1$ (0,45)	200	0,369	0,175	0,278	23,2%	58,7%	18,0%	<b>0,479</b>	<b>0,174</b>	<b>0,203</b>	<b>59,8%</b>	<b>16,9%</b>	<b>81,8%</b>
	300	0,360	0,174	0,275	20,0%	58,6%	24,8%	<b>0,460</b>	<b>0,163</b>	<b>0,180</b>	<b>53,2%</b>	<b>10,7%</b>	<b>87,0%</b>
	400	0,350	0,148	0,268	16,7%	81,0%	26,4%	<b>0,472</b>	<b>0,163</b>	<b>0,169</b>	<b>57,4%</b>	<b>3,6%</b>	<b>91,0%</b>
	500	0,373	0,160	0,232	24,2%	45,2%	36,4%	<b>0,473</b>	<b>0,152</b>	<b>0,159</b>	<b>57,5%</b>	<b>4,7%</b>	<b>93,6%</b>
$x_2$ (0,35)	200	0,327	0,195	0,259	9,0%	33,3%	16,0%	0,399	0,159	0,170	32,8%	7,3%	75,8%
	300	0,293	0,136	0,200	-2,2%	47,2%	21,2%	<b>0,384</b>	<b>0,148</b>	<b>0,152</b>	<b>28,1%</b>	<b>2,4%</b>	<b>83,4%</b>
	400	0,279	0,126	0,193	-7,1%	54,1%	20,8%	<b>0,366</b>	<b>0,131</b>	<b>0,129</b>	<b>21,9%</b>	<b>-1,4%</b>	<b>87,8%</b>
	500	0,279	0,139	0,181	-7,0%	30,5%	36,4%	<b>0,356</b>	<b>0,114</b>	<b>0,114</b>	<b>18,6%</b>	<b>0,0%</b>	<b>91,0%</b>
$x_3$ (0,25)	200	0,237	0,152	0,188	-21,1%	23,9%	11,9%	0,300	0,143	0,137	0,0%	-4,3%	62,8%
	300	0,217	0,129	0,162	-27,7%	25,8%	15,9%	0,273	0,115	0,115	-9,1%	0,0%	71,1%
	400	0,199	0,096	0,130	-33,5%	35,0%	18,9%	0,259	0,098	0,099	-13,8%	1,7%	75,8%
	500	0,178	0,059	0,117	-40,7%	98,0%	18,2%	<b>0,255</b>	<b>0,091</b>	<b>0,090</b>	<b>-15,1%</b>	<b>-1,1%</b>	<b>82,6%</b>
$x_4$ (0,15)	200	0,134	0,141	0,149	-55,3%	5,6%	7,0%	0,189	0,133	0,120	-37,1%	-9,8%	33,8%
	300	0,140	0,120	0,131	-53,3%	9,4%	7,1%	0,170	0,112	0,102	-43,4%	-9,0%	39,3%
	400	0,123	0,065	0,114	-59,2%	76,1%	0,0%	0,163	0,094	0,088	-45,5%	-6,4%	45,2%
	500	0,131	0,085	0,102	-56,3%	20,4%	9,1%	0,157	0,083	0,079	-47,6%	-5,1%	50,3%

Tabla 13.  $n = 5$  (entre paréntesis el valor poblacional de lambda para cada  $x_i$ )

$x_i$	$N$	$H_0$ modelo independencia (T2)						$H_1$ modelo independencia (T1)					
		Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.	Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.
$x_1$ (0,3)	200	0,242	0,130	0,150	-19,3%	15,6%	30,9%	0,323	0,129	0,119	7,5%	-8,2%	79,9%
	300	0,258	0,091	0,138	-13,9%	51,8%	35,0%	<b>0,310</b>	<b>0,102</b>	<b>0,099</b>	<b>3,3%</b>	<b>-3,1%</b>	<b>90,8%</b>
	400	0,222	0,072	0,121	-26,1%	69,5%	66,7%	<b>0,304</b>	<b>0,088</b>	<b>0,085</b>	<b>1,4%</b>	<b>-3,1%</b>	<b>94,8%</b>
	500	---	---	---	---	---	---	<b>0,303</b>	<b>0,078</b>	<b>0,076</b>	<b>1,0%</b>	<b>-2,8%</b>	<b>97,9%</b>
$x_2$ (0,2)	200	0,154	0,119	0,130	-48,6%	9,4%	7,4%	0,215	0,131	0,110	-28,2%	-15,6%	51,1%
	300	0,140	0,087	0,110	-53,4%	26,5%	20,0%	0,199	0,094	0,090	-33,7%	-4,2%	59,3%
	400	0,096	0,024	0,093	-68,1%	280,2%	0,0%	0,199	0,082	0,079	-33,5%	-4,0%	71,2%
	500	---	---	---	---	---	---	<b>0,199</b>	<b>0,073</b>	<b>0,071</b>	<b>-33,7%</b>	<b>-3,2%</b>	<b>81,4%</b>
$x_3$ (0,1)	200	0,073	0,111	0,123	-75,8%	10,6%	4,3%	0,106	0,125	0,105	-64,7%	-15,8%	20,6%
	300	0,059	0,096	0,106	-80,3%	10,1%	5,0%	0,104	0,096	0,088	-65,4%	-8,8%	23,8%
	400	0,039	0,050	0,083	-87,0%	65,2%	0,0%	0,101	0,083	0,077	-66,5%	-8,2%	27,2%
	500	---	---	---	---	---	---	0,101	0,073	0,069	-66,4%	-5,8%	31,9%
$x_4$ (0,4)	200	0,318	0,164	0,180	5,9%	10,1%	39,4%	<b>0,420</b>	<b>0,147</b>	<b>0,137</b>	<b>40,1%</b>	<b>-6,7%</b>	<b>91,9%</b>
	300	0,290	0,120	0,151	-3,5%	25,9%	50,0%	<b>0,408</b>	<b>0,118</b>	<b>0,114</b>	<b>36,1%</b>	<b>-3,5%</b>	<b>97,0%</b>
	400	0,391	0,241	0,268	30,4%	11,2%	66,7%	<b>0,402</b>	<b>0,100</b>	<b>0,099</b>	<b>34,0%</b>	<b>-1,5%</b>	<b>98,6%</b>
	500	---	---	---	---	---	---	<b>0,403</b>	<b>0,096</b>	<b>0,089</b>	<b>34,4%</b>	<b>-7,5%</b>	<b>99,6%</b>
$x_5$ (0,5)	200	0,448	0,197	0,260	49,5%	31,7%	48,9%	<b>0,504</b>	<b>0,167</b>	<b>0,157</b>	<b>68,2%</b>	<b>-5,7%</b>	<b>94,8%</b>
	300	0,388	0,138	0,193	29,2%	39,8%	60,0%	<b>0,511</b>	<b>0,134</b>	<b>0,136</b>	<b>70,3%</b>	<b>1,2%</b>	<b>98,5%</b>
	400	0,328	0,152	0,160	9,3%	5,0%	66,7%	<b>0,511</b>	<b>0,126</b>	<b>0,122</b>	<b>70,3%</b>	<b>-3,2%</b>	<b>99,2%</b>
	500	---	---	---	---	---	---	<b>0,507</b>	<b>0,113</b>	<b>0,107</b>	<b>69,1%</b>	<b>-5,4%</b>	<b>99,6%</b>



Si la heterogeneidad en la magnitud de las cargas factoriales es elevada, las cargas más altas potenciarán el rechazo del modelo de independencia y el ajuste teórico global, si bien puede estar comprometida la potencia en la estimación de las cargas más bajas. En cualquier caso, la discriminación inicial de soluciones T2 evita analizar modelos estimados con muy poca potencia.

En la condición  $n = 5$ :  $\lambda_{ij}$  (0,1-0,5) se observan valores de potencia por encima del 80% a partir de  $N = 500$  para  $\lambda_{ij} = 0,2$ , a partir de  $N = 300$  para  $\lambda_{ij} = 0,3$  y a partir de  $N = 200$  para  $\lambda_{ij} = 0,4$  y  $\lambda_{ij} = 0,5$ . Para estimar con precisión  $\lambda_{ij} = 0,1$  se necesitarían tamaños muestrales bastante más elevados a los simulados (con  $N = 500$  se obtiene un valor de potencia del 31,9% en las soluciones T1). Los resultados de la pre-evaluación indican para  $N = 200$  un 80,7% de soluciones T1, junto a un 9,9% de soluciones IM (Tabla 6).

Con datos ordinales y distribución simétrica (5D1) se obtienen niveles aceptables de potencia en la estimación de cargas fijas en 0,3, 5 variables observables y 500 observaciones (Tabla 14). Los resultados de la pre-evaluación indicaron un 91,9% de soluciones T1 y un 5,6% de soluciones IM a partir de  $N = 300$  (ver Tabla 5). Con  $n = 6$  se obtienen valores adecuados de potencia a partir de  $N = 400$ . Con distribución asimétrica (5D2) no hay potencia suficiente para la estimación, incluso aumentando el número de variables observables a  $n = 6$ , mientras que la pre-evaluación arrojaba un 89% de soluciones T1 y un 1,4% de soluciones IM con  $N = 400$  y  $n = 5$ . No obstante, cuando la distribución de los datos es asimétrica, el ajuste teórico (valor promedio de  $C_j$ ) no alcanzaba los valores recomendados incluso con 500 observaciones, lo que resulta coherente con los resultados mostrados en la Tabla 14.

Tabla 14. Resultados obtenidos en relación a los estudios de potencia con datos ordinales. Nivel fijo de  $\lambda_{ij} = 0,3$ ,  $n = 5$ , distribución simétrica (5D1), estimación RDWLS

$x_i$	$N$	$H_0$ modelo independencia (T2)						$H_1$ modelo independencia (T1)					
		Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.	Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.
$x_1$	200	0,268	0,177	0,346	-10,6%	94,9%	8,2%	0,321	0,151	0,174	7,1%	15,5%	51,8%
	300	0,254	0,161	0,365	-15,4%	126,0%	8,9%	0,316	0,127	0,144	5,4%	13,1%	65,1%
	400	0,243	0,087	0,268	-18,9%	207,3%	8,3%	0,307	0,114	0,121	2,5%	6,3%	76,0%
	500	0,223	0,081	0,193	-25,6%	138,8%	0,0%	<b>0,307</b>	<b>0,101</b>	<b>0,105</b>	<b>2,3%</b>	<b>3,3%</b>	<b>85,9%</b>
$x_2$	200	0,230	0,206	0,292	-23,2%	41,8%	7,5%	0,308	0,186	0,183	2,7%	-1,5%	52,4%
	300	0,231	0,180	0,273	-22,9%	52,0%	3,6%	0,301	0,128	0,141	0,2%	10,0%	61,9%
	400	0,206	0,178	0,248	-31,4%	39,2%	16,7%	0,297	0,114	0,122	-1,0%	7,1%	74,8%
	500	0,156	0,082	0,161	-47,9%	96,3%	16,7%	<b>0,296</b>	<b>0,099</b>	<b>0,103</b>	<b>-1,3%</b>	<b>4,3%</b>	<b>84,3%</b>
$x_3$	200	0,221	0,161	0,278	-26,5%	72,1%	7,5%	0,321	0,185	0,184	7,1%	-0,7%	51,8%
	300	0,243	0,170	0,312	-18,9%	83,8%	3,6%	0,315	0,129	0,144	5,2%	11,1%	66,2%
	400	0,196	0,103	0,203	-34,8%	97,2%	0,0%	0,310	0,118	0,121	3,4%	2,3%	77,1%
	500	0,224	0,142	0,231	-25,4%	62,6%	33,3%	<b>0,304</b>	<b>0,102</b>	<b>0,103</b>	<b>1,4%</b>	<b>1,4%</b>	<b>83,9%</b>
$x_4$	200	0,261	0,194	0,338	-13,1%	73,7%	10,3%	0,313	0,177	0,183	4,5%	3,5%	53,0%
	300	0,248	0,152	0,238	-17,2%	56,9%	12,5%	0,309	0,128	0,141	3,2%	10,2%	66,5%
	400	0,224	0,107	0,219	-25,3%	104,8%	25,0%	0,306	0,115	0,122	1,8%	5,9%	75,5%
	500	0,269	0,097	0,369	-10,3%	281,9%	33,3%	<b>0,306</b>	<b>0,102</b>	<b>0,104</b>	<b>2,1%</b>	<b>2,2%</b>	<b>84,4%</b>
$x_5$	200	0,226	0,226	0,347	-24,8%	53,7%	5,5%	0,307	0,172	0,173	2,4%	0,4%	50,4%
	300	0,179	0,115	0,213	-40,3%	84,4%	1,8%	0,311	0,132	0,143	3,6%	8,3%	67,0%
	400	0,244	0,111	0,230	-18,6%	107,5%	8,3%	0,305	0,116	0,120	1,8%	3,6%	77,2%
	500	0,179	0,093	0,316	-40,3%	240,8%	0,0%	<b>0,306</b>	<b>0,102</b>	<b>0,104</b>	<b>1,9%</b>	<b>2,4%</b>	<b>87,4%</b>

Cuando las cargas simuladas se fijaron en 0,4 se obtienen valores adecuados de potencia incluso en la distribución más asimétrica a partir de 400 observaciones y  $n = 4 - 5$  (ver Tabla 15), o a partir de 300 observaciones con  $n = 6$ .

Tabla 15. Resultados obtenidos en relación a los estudios de potencia con datos ordinales. Nivel fijo de  $\lambda_{ij}$  ( $\lambda_{ij} = 0,4$ ),  $n = 5$ , distribución asimétrica (5D2), estimación RDWLS

$x_i$	$N$	$H_0$ modelo independencia (T2)						$H_1$ modelo independencia (T1)					
		Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.	Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.
$x_1$	200	0,214	0,154	0,337	-46,4%	118,9%	0,0%	0,395	0,172	0,190	-1,3%	10,4%	59,5%
	300	---	---	---	---	---	---	0,397	0,138	0,149	-0,6%	8,5%	77,9%
	400	---	---	---	---	---	---	<b>0,398</b>	<b>0,123</b>	<b>0,125</b>	<b>-0,5%</b>	<b>2,1%</b>	<b>86,8%</b>
	500	---	---	---	---	---	---	<b>0,400</b>	<b>0,109</b>	<b>0,110</b>	<b>0,1%</b>	<b>0,2%</b>	<b>94,8%</b>
$x_2$	200	0,306	0,149	0,313	-23,5%	110,2%	0,0%	0,398	0,199	0,199	-0,5%	-0,2%	61,7%
	300	---	---	---	---	---	---	0,392	0,156	0,153	-1,9%	-1,9%	78,0%
	400	---	---	---	---	---	---	<b>0,397</b>	<b>0,119</b>	<b>0,125</b>	<b>-0,8%</b>	<b>4,8%</b>	<b>88,2%</b>
	500	---	---	---	---	---	---	<b>0,398</b>	<b>0,105</b>	<b>0,109</b>	<b>-0,4%</b>	<b>3,4%</b>	<b>94,7%</b>
$x_3$	200	0,194	0,339	0,292	-51,6%	-14,0%	0,0%	0,408	0,198	0,199	2,1%	0,5%	62,9%
	300	---	---	---	---	---	---	0,408	0,161	0,154	1,9%	-4,3%	78,4%
	400	---	---	---	---	---	---	<b>0,407</b>	<b>0,126</b>	<b>0,126</b>	<b>1,9%</b>	<b>-0,5%</b>	<b>90,0%</b>
	500	---	---	---	---	---	---	<b>0,406</b>	<b>0,108</b>	<b>0,110</b>	<b>1,5%</b>	<b>2,6%</b>	<b>96,2%</b>
$x_4$	200	0,328	0,188	0,568	-17,9%	201,5%	0,0%	0,402	0,185	0,193	0,5%	4,1%	62,9%
	300	---	---	---	---	---	---	0,397	0,155	0,151	-0,7%	-2,7%	78,4%
	400	---	---	---	---	---	---	<b>0,401</b>	<b>0,124</b>	<b>0,125</b>	<b>0,2%</b>	<b>1,1%</b>	<b>89,3%</b>
	500	---	---	---	---	---	---	<b>0,401</b>	<b>0,105</b>	<b>0,109</b>	<b>0,2%</b>	<b>3,9%</b>	<b>95,6%</b>
$x_5$	200	0,146	0,099	0,307	-63,5%	211,1%	0,0%	0,393	0,192	0,202	-1,7%	5,2%	62,0%
	300	---	---	---	---	---	---	0,400	0,150	0,152	0,0%	1,4%	79,3%
	400	---	---	---	---	---	---	<b>0,401</b>	<b>0,117</b>	<b>0,126</b>	<b>0,2%</b>	<b>7,4%</b>	<b>89,3%</b>
	500	---	---	---	---	---	---	<b>0,402</b>	<b>0,109</b>	<b>0,110</b>	<b>0,5%</b>	<b>0,8%</b>	<b>94,6%</b>

En condiciones simuladas a partir de cargas heterogéneas la potencia decrece respecto a los estudios realizados sobre datos continuos. En la condición  $n = 4$ :  $\lambda_{ij}$  (0,15-0,45) y estimación RDWLS solamente la estimación del parámetro  $\lambda_{ij} = 0,45$  ( $x_1$ ) obtiene niveles de potencia por encima del 80% con  $N = 500$ . En condiciones de asimetría (5D2) ninguno de los parámetros se estima con la suficiente potencia. En la condición  $n = 5$ :  $\lambda_{ij}$  (0,1-0,5) y estimación RDWLS se observa la necesidad de ampliar el número de observaciones en la condición simétrica (5D1) para alcanzar resultados similares a los obtenidos a partir de los datos continuos (ver Tabla 16). En condiciones de asimetría (5D2) se obtienen resultados muy similares. Sobre las condiciones simuladas a partir de 3 variables observables ( $n = 3$ ), cuando la magnitud de las cargas se fijó

en 0,3 no se obtiene la potencia suficiente para estimar los parámetros con la suficiente precisión. Cuando las cargas se fijaron en 0,4 se obtienen valores  $>$  del 80% a partir de  $N = 400$  en la distribución simétrica (5D1), y cuando las cargas se fijaron en 0,5 se obtienen estos valores de potencia a partir de  $N = 300$  incluso en la distribución más asimétrica (5D2).

Tabla 16. Resultados obtenidos en relación a los estudios de potencia con datos ordinales. Cargas heterogéneas,  $n = 5$ , distribución simétrica (5D1), estimación RDWLS

$x_i$	$N$	$H_0$ modelo independencia (T2)						$H_1$ modelo independencia (T1)					
		Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.	Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.
$x_1$ (0,3)	200	0,237	0,120	0,241	-20,8%	102,0%	8,9%	0,323	0,144	0,163	7,6%	13,2%	59,2%
	300	0,213	0,070	0,206	-29,1%	193,7%	0,0%	0,312	0,112	0,130	3,9%	16,2%	72,7%
	400	0,144	0,047	0,175	-52,0%	275,1%	0,0%	<b>0,306</b>	<b>0,096</b>	<b>0,106</b>	<b>1,9%</b>	<b>10,3%</b>	<b>83,0%</b>
	500	---	---	---	---	---	---	<b>0,305</b>	<b>0,085</b>	<b>0,092</b>	<b>1,5%</b>	<b>8,2%</b>	<b>91,6%</b>
$x_2$ (0,2)	200	0,166	0,198	0,266	-17,0%	34,4%	2,5%	0,214	0,151	0,166	6,8%	10,1%	35,2%
	300	0,112	0,127	0,192	-43,9%	51,9%	0,0%	0,201	0,105	0,117	0,7%	10,7%	43,1%
	400	0,088	0,044	0,183	-55,8%	314,1%	0,0%	0,202	0,092	0,098	0,9%	5,9%	56,6%
	500	---	---	---	---	---	---	0,200	0,080	0,086	0,1%	7,9%	67,8%
$x_3$ (0,1)	200	0,079	0,136	0,201	-21,1%	47,2%	2,5%	0,110	0,148	0,146	10,2%	-1,6%	15,6%
	300	0,076	0,139	0,166	-23,9%	19,7%	0,0%	0,108	0,109	0,112	7,5%	2,7%	17,2%
	400	0,128	0,041	0,137	28,3%	237,3%	0,0%	0,104	0,094	0,095	4,3%	0,5%	21,1%
	500	---	---	---	---	---	---	0,102	0,082	0,083	2,5%	1,4%	23,5%
$x_4$ (0,4)	200	0,323	0,215	0,380	-19,3%	77,3%	12,7%	0,420	0,177	0,196	5,0%	10,9%	69,1%
	300	0,384	0,235	0,432	-4,1%	83,4%	7,1%	<b>0,416</b>	<b>0,135</b>	<b>0,155</b>	<b>4,0%</b>	<b>15,3%</b>	<b>82,3%</b>
	400	0,330	0,071	0,404	-17,5%	467,1%	33,3%	<b>0,410</b>	<b>0,115</b>	<b>0,132</b>	<b>2,5%</b>	<b>15,3%</b>	<b>89,8%</b>
	500	---	---	---	---	---	---	<b>0,408</b>	<b>0,102</b>	<b>0,110</b>	<b>1,9%</b>	<b>7,6%</b>	<b>95,8%</b>
$x_5$ (0,5)	200	0,377	0,236	0,399	-24,5%	69,3%	12,7%	0,490	0,188	0,222	-2,0%	18,2%	74,0%
	300	0,278	0,164	0,270	-44,4%	64,6%	7,1%	<b>0,504</b>	<b>0,149</b>	<b>0,187</b>	<b>0,8%</b>	<b>25,5%</b>	<b>85,0%</b>
	400	0,384	0,083	0,415	-23,1%	402,9%	33,3%	<b>0,506</b>	<b>0,135</b>	<b>0,164</b>	<b>1,3%</b>	<b>21,7%</b>	<b>92,7%</b>
	500	---	---	---	---	---	---	<b>0,506</b>	<b>0,120</b>	<b>0,136</b>	<b>1,3%</b>	<b>13,4%</b>	<b>96,4%</b>

El análisis de los datos dicotómicos arroja una enorme pérdida de potencia respecto a los resultados anteriores. Estos resultados son consistentes con la recomendación de no utilizar ítems dicotómicos con cargas inferiores a 0,4 que proponen Forero et al. (2009). La Tabla 17 muestra los valores de potencia obtenidos en la mejor de las condiciones simuladas (cargas fijas

en 0,3,  $n = 6$ , escenario de simetría) y a partir de la estimación RDWLS. Los mejores valores de potencia apenas superan el 60% en la condición  $N = 500$  dentro de las soluciones T1. Las condiciones para aplicar AFC con este tipo de datos deben ser bastante más exigentes, como se indicó en apartados anteriores.

Tabla 17. Resultados obtenidos en relación a los estudios de potencia con datos dicotómicos. Nivel fijo de  $\lambda_{ij} = 0,3$ ,  $n = 6$ , distribución simétrica (2D1), estimación RDWLS

$x_i$	$N$	$H_0$ modelo independencia (T2)						$H_1$ modelo independencia (T1)					
		Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.	Mean	S.D.	S.E. average	Param. bias (%)	S.E. bias (%)	% Sig. Coeff.
$x_1$	200	0,343	0,285	1,035	14,4%	262,8%	0,0%	0,308	0,182	0,251	2,6%	38,5%	28,6%
	300	0,197	0,203	0,304	-34,5%	50,1%	0,0%	0,303	0,158	0,192	1,1%	21,1%	40,1%
	400	---	---	---	---	---	---	0,296	0,142	0,162	-1,4%	14,5%	51,2%
	500	---	---	---	---	---	---	0,296	0,124	0,136	-1,4%	10,2%	59,9%
$x_2$	200	0,097	0,228	0,362	-67,5%	58,7%	0,0%	0,280	0,265	0,268	-6,6%	1,1%	31,7%
	300	0,086	0,227	0,366	-71,5%	61,2%	0,0%	0,292	0,203	0,196	-2,8%	-3,3%	41,7%
	400	---	---	---	---	---	---	0,300	0,169	0,167	0,0%	-1,7%	52,4%
	500	---	---	---	---	---	---	0,303	0,140	0,142	1,1%	1,1%	64,1%
$x_3$	200	0,151	0,236	0,428	-49,8%	81,2%	0,0%	0,273	0,243	0,253	-8,9%	3,8%	27,9%
	300	0,046	0,339	0,387	-84,8%	14,0%	0,0%	0,277	0,192	0,190	-7,6%	-0,7%	40,5%
	400	---	---	---	---	---	---	0,293	0,157	0,168	-2,3%	7,4%	53,2%
	500	---	---	---	---	---	---	0,298	0,139	0,141	-0,7%	2,1%	63,0%
$x_4$	200	0,099	0,226	0,315	-67,1%	39,1%	0,0%	0,278	0,252	0,265	-7,2%	5,2%	29,5%
	300	-0,133	0,451	0,908	-144,3%	101,2%	0,0%	0,296	0,193	0,193	-1,3%	0,0%	41,4%
	400	---	---	---	---	---	---	0,302	0,158	0,164	0,6%	3,7%	52,4%
	500	---	---	---	---	---	---	0,301	0,140	0,144	0,4%	3,4%	63,0%
$x_5$	200	0,148	0,119	0,348	-50,5%	191,8%	0,0%	0,279	0,252	0,255	-6,9%	1,5%	31,1%
	300	0,013	0,223	0,324	-95,7%	45,2%	0,0%	0,299	0,195	0,198	-0,3%	1,4%	41,9%
	400	---	---	---	---	---	---	0,301	0,159	0,166	0,4%	4,1%	55,2%
	500	---	---	---	---	---	---	0,302	0,136	0,140	0,7%	2,5%	65,8%
$x_6$	200	0,198	0,361	0,763	-34,0%	111,5%	0,0%	0,283	0,242	0,251	-5,8%	3,7%	31,5%
	300	0,054	0,132	0,254	-82,0%	93,0%	0,0%	0,294	0,186	0,192	-1,8%	3,0%	43,4%
	400	---	---	---	---	---	---	0,302	0,151	0,163	0,5%	8,1%	53,8%
	500	---	---	---	---	---	---	0,302	0,130	0,140	0,6%	7,2%	62,5%

# CAPÍTULO 4

Discusión y conclusiones

## CAPÍTULO 4: Discusión y conclusiones

El objetivo del presente trabajo ha sido proporcionar fuentes adicionales de evidencia empírica sobre la adecuación de incluir o rechazar factores que presentan cargas factoriales reducidas (los denominados en este trabajo como factores VCL), ante determinadas condiciones de aplicación frecuentes en la práctica convencional del AFC en Psicología. Para ello, se ha destacado la importancia de aislar el factor o dimensión comprometida del resto de influencias del modelo, no solo como una cuestión de carácter procedimental o instrumental, sino desde una perspectiva *theory-driven*. Para ello, se han simulado distintas soluciones que proceden de estructuras poblacionales unifactoriales. La mayor parte de las soluciones factoriales analizadas se han elaborado a partir de la simulación de factores con valores de  $\lambda_{ij}$  entre 0,2 y 0,4 con el fin de evaluar hasta qué punto los factores estimados reflejan adecuadamente el constructo o variable latente que asumimos que existe en la realidad. En este sentido, en el presente trabajo se ha adoptado una posición realista en la que se asume que las variables latentes existen independientemente de las variables observables a partir de las que se infieren. En un sentido confirmatorio, los investigadores ponen a prueba constructos o conceptos hipotéticos que se asumen como verdaderos en la realidad aunque no sean directamente observables. La condición de *pseudo*-aislamiento se establece a partir de la asunción matemática de que el error de medida no está relacionado con la variable latente ( $\text{COV}(\xi_i, \delta_i) = 0$ ) y la identificabilidad de los modelos se garantiza mediante la especificación de clústers independientes. Al menos, este es el esquema operativo que se viene aplicando con mayor frecuencia en la práctica convencional del AFC durante las últimas décadas.

Que la magnitud de los parámetros sea reducida tiene distintas implicaciones dependiendo de si nos referimos a  $\lambda_{ij}$  o a  $\hat{\lambda}_{ij}$ . Como se ha argumentado en este trabajo, la valoración del grado de interconexión de los distintos procesos de la realidad, así como la valoración de su verosimilitud, corresponde a los procesos de decisión, consenso y validación de teorías por *expert committes*, entendiendo que la búsqueda de correspondencias entre  $\hat{\Sigma}_0$  y  $S$  es una herramienta de trabajo. Desde la perspectiva probabilística que domina las Ciencias Sociales se entiende que no es posible explicar la totalidad de los fenómenos y problemas estudiados, dada su enorme complejidad. Por consiguiente, que la magnitud del parámetro poblacional sea reducida puede deberse a factores no tenidos en cuenta desde la teoría, puede deberse a que  $\hat{\Sigma}_0$  no incluya en su sistema de ecuaciones toda la información necesaria para reflejar  $\Sigma$  (y que puede estar o no presente en la teoría), o puede deberse a ambas cosas. Desarrollos pobres o limitados de la teoría serán los desencadenantes del primero de estos aspectos, mientras que algunas limitaciones propias de los instrumentos y del proceso de medición serán desencadenantes del segundo. Ejemplos de limitaciones de carácter teórico podemos encontrar en la inmensa mayoría de modelos tentativos en Psicología (escenario MG), como los que provienen de AFE previo, por ejemplo. Las limitaciones propias del proceso de medición se relacionan con la ausencia de una teoría del error, restricciones en el contenido evaluado, fenómenos de estudio con prevalencias bajas, limitaciones en la definición de la población objetivo, o en la idoneidad y accesibilidad de dichas poblaciones, entre otras.

Por el contrario, cuando nos referimos a magnitudes reducidas de  $\hat{\lambda}_{ij}$  el tipo de implicaciones difiere del anterior, ya que lo que está comprometido no es necesariamente la teoría, el sistema de ecuaciones propuesto o los instrumentos de medición, *sino la propia sensibilidad de la herramienta analítica para detectar ciertos patrones de relación en los datos obtenidos a partir de determinadas condiciones de aplicación*. Más tarde, en caso de obtener



evidencias de consistencia empírica, los *expert commites* decidirán si el valor poblacional que se infiere de los resultados del análisis es lo suficientemente elevado o relevante en función de los objetivos perseguidos y de la investigación previa. En la misma línea, pero en sentido contrario, que los parámetros estimados tengan magnitudes altas no deriva necesariamente en teoría, sino que lo que está comprometido y lo que hay que valorar y validar es la capacidad para reflejar la heterogeneidad del constructo representado. La primera conclusión que puede extraerse cuando se obtienen magnitudes elevadas es que se cumplen las condiciones necesarias para una estimación precisa; después habrá que valorar hasta qué punto existen fuentes de validez adicionales que confieran naturaleza teórica al constructo evaluado.

Es cierto que se ha hecho un importante esfuerzo por aclarar y transmitir cuáles son los principios fundamentales que deben orientar la aplicación del AF en la investigación aplicada, tanto en la modalidad AFE como en la AFC, y que son muchos los autores que han estudiado el tipo de condiciones que son deseables para una correcta aplicación. No obstante, no es menos cierto que existe un importante *gap* entre el conocimiento desarrollado hasta la fecha sobre la aplicación de la técnica y su práctica convencional. Sin pretender ahondar en estas cuestiones, podríamos citar algunos de los motivos más importantes que a nuestro juicio han intervenido en la configuración de esta separación. En primer lugar, no parece haberse entendido bien el enfoque causal que subyace al desarrollo del AFC, desdibujándose las diferencias entre la aproximación exploratoria y la confirmatoria. La cuestión de la causalidad ha sido ampliamente abordada por autores tan relevantes como Bollen, McDonald, Mulaik, Kline o Hoyle y está volviendo a cobrar fuerza de nuevo a través de autores como Pearl, aunque no parece que se haya generalizado el interés por profundizar en este aspecto fundamental de la técnica entre la comunidad investigadora. En otros términos, esta falta de interés se plasma en la tendencia a desatender la interpretación de los modelos a nivel “local”, esto es a dotar de sentido teórico y

poner a prueba cada una de las dimensiones o factores que compone el modelo AFC. Esto es, se desatiende con demasiada frecuencia la interpretación de las “*localized areas of strain*” (Brown. 2015, p. 97), atendiendo solamente a las re-especificaciones que permiten mejorar el ajuste del modelo multidimensional.

En segundo lugar, el carácter confirmatorio de la técnica, así como su potencialidad y complejidad, parece haber desdibujado también las diferencias entre la investigación experimental y la no experimental, constituyendo un caso excepcional de investigación aplicada que tiende a idealizar las condiciones en las que se desarrolla y que potencia la aparición de sesgos confirmatorios. Lo anterior se desprende de la excesiva “validación” de modelos teóricos a partir de una sola muestra. En tercer lugar, el marcado carácter multidisciplinar en el que se ha desarrollado la técnica podría haber contribuido a desdibujar los objetivos propios de nuestra disciplina. En este sentido, si bien la validez de constructo es un aspecto transversal a toda ciencia que trate de estudiar variables latentes, hay que reconocer que este concepto cobra especial relevancia en el campo de la Psicología. La revisión de la práctica de publicación o RPP indica que esta cuestión es desatendida con demasiada frecuencia.

Por último, también es verdad que buena parte de los esfuerzos realizados se han focalizado en el análisis de datos continuos, frente a la tipología de datos de la dispone el investigador aplicado. Pasar de analizar datos ideales desde el punto de vista estadístico a trabajar con los datos de tipo ordinal-discreto que encontramos en la práctica supone un salto cualitativo importante, en donde se intensifican las limitaciones de la técnica. Este salto parece no haber sido bien entendido desde la práctica convencional.

La recomendación de utilizar ciertos puntos de corte sobre los valores de  $\hat{\lambda}_{ij}$  que resultan adecuados para interpretar modelos factoriales parece ser equívoca en la práctica convencional, lo que plantea la necesidad de una revisión y de una traducción a otros términos desde el punto

de vista aplicado. Es equívoca por diferentes razones, varias de las cuales ya han sido argumentadas en el presente trabajo. La aplicación de puntos de corte es ciega al contenido del constructo evaluado pudiendo ser eliminados aspectos relevantes desde un punto de vista teórico antes incluso de ser puestos a prueba. Todo ello puede estar derivando en una excesiva infrarrepresentación de ciertos constructos psicológicos en aras de una mayor eficacia y precisión en la recuperación de parámetros. En este sentido, podría confundirse la simplicidad de determinados modelos con la aplicación del principio de parsimonia. Además, no parece existir demasiado acuerdo sobre cuáles son estos puntos de corte, lo que nos lleva a incidir nuevamente en la importancia del contexto de aplicación y en la fase de desarrollo en la que se encuentra cada modelo evaluado. Al mismo tiempo, considerar exclusivamente el valor de  $\hat{\lambda}_{ij}$  puede resultar equívoco si no se consideran otras fuentes de variación desde el punto de vista de la recuperación de parámetros. La adecuada estimación de modelos mediante AFC es una cuestión compleja que solamente puede resolverse atendiendo a distintas combinaciones de variables y condiciones (efecto compensatorio entre variables), y esta cuestión es más difícil de resolver en los contextos aplicados que en la investigación de carácter metodológico.

Pero entonces, ¿qué tipo de decisión puede tomarse en investigación aplicada cuando las variables observables que representan determinados constructos hipotéticos presentan valores bajos de  $\hat{\lambda}_{ij}$ ? ¿Qué traducción o cambio de enfoque se puede transmitir a los investigadores aplicados respecto al significado de los valores estimados de las cargas factoriales cuando estas son bajas? Básicamente, una sola cuestión sirve para dar respuesta a ambos interrogantes: *el problema no tiene por qué estar necesariamente en el constructo evaluado, lo que hay que revisar es si las condiciones de aplicación son suficientes para analizar y evaluar variables latentes mediante AFC*. Recordemos que en el Capítulo 1 se introdujo una diferenciación entre decisiones de tipo heurístico y decisiones fundamentadas en la pre-evaluación de factores VCL,

ante la posibilidad de que un determinado factor pueda ser interpretado como “ruido” o como “señal”. En ese capítulo ya se diferenciaban las estrategias *data-driven* y las estrategias *theory-driven* que pueden adoptarse en el proceso de toma de decisiones. Las primeras, correspondientes a las decisiones de tipo heurístico, ponen el foco del problema en la naturaleza del constructo al eliminar variables observables (incluso factores) que no superan los puntos de corte. El segundo tipo de decisiones se sustentan en evidencias de consistencia empírica del constructo en cada muestra concreta y evalúan la sensibilidad del AFC en tanto que herramienta de análisis, asumiendo que el problema estará en las condiciones de aplicación. El constructo hipotético existe en la población, solo que no somos capaces de detectarlo mediante AFC en las condiciones en las que ha sido evaluado. Todo esto, a nuestro juicio, supone un importante y necesario cambio de enfoque respecto a la práctica habitual del AFC y una “traducción” respecto a las implicaciones que tienen las magnitudes de  $\hat{\lambda}_{ij}$  en la investigación aplicada. Es cierto que esta distinción entre decisiones heurísticas y decisiones fundamentadas en la pre-evaluación de factores VCL puede interpretarse como demasiado simplista. No obstante, mediante este cambio de enfoque y traducción conceptual se pretende potenciar la reinserción de aspectos relacionados con la validez de constructo como objetivo prioritario en aquella investigación en Psicología que trata de medir, representar e interpretar variables latentes. Además, este tipo de distinciones son consistentes con varias de las recomendaciones que aparecen en varios de los trabajos que revisan la práctica convencional AF y SEM (por ejemplo, MacCallum y Austin, 2000; McDonald y Ho, 2002).

¿Cómo podemos decidir si el factor VCL evaluado es “ruido” o es “señal”? En el presente trabajo se ha propuesto poner a prueba la  $H_0$  del modelo de independencia, en combinación con este cambio de enfoque que da preeminencia a la existencia del constructo evaluado en la realidad, frente a decisiones de tipo heurístico. Recordemos que todos los modelos simulados

en este trabajo, aunque con magnitudes limitadas, son verdaderos en la población (lo que no quiere decir que sean relevantes, esta decisión se tomaría después). Por tanto, lo que se ha tratado de evaluar ha sido el grado en el que la aplicación del AFC permite “capturar” la estructura a nivel poblacional en ciertas condiciones que podrían considerarse en el límite de lo aceptable.

Los resultados han revelado que la estimación de modelos unifactoriales que no difieren estadísticamente del modelo nulo ( $\Sigma_{Null}$ ) aumenta claramente en aquellas condiciones en las que los valores simulados de  $\lambda_{ij}$  son más bajos, y dentro de cada nivel simulado de  $\lambda_{ij}$ , en aquellas soluciones con valores más bajos de  $\hat{\lambda}_{ij}$ . En otras palabras, existe una mayor proporción de soluciones T2 en las soluciones estimadas en la condición  $\lambda_{ij} = 0,2$  que en la condición  $\lambda_{ij} = 0,3$  (en la condición  $\lambda_{ij} = 0,4$  prácticamente desaparecen). Y dentro de cada uno de estos niveles simulados de  $\lambda_{ij}$  (0,2, 0,3 y 0,4), en aquellas soluciones en las que se infraestima el parámetro poblacional. Una primera conclusión a la que se puede llegar a partir de esta información es que la recomendación de considerar como salientes estimaciones del parámetro en torno al valor 0,3 y, especialmente, en torno a 0,4 no es incorrecta. Esta conclusión ya se desprende de estudios previos, como el de De Winter et al. (2009) en el marco del AFE y como los de Gagné y Hancock (2006) y Ximénez (2006, 2007, 2009, 2016) en el marco del AFC. El problema de los puntos de corte es que su aplicación no es unívoca, ya que depende de la combinación de los diferentes niveles del resto de variables estudiadas (tamaño muestral, n° de variables observables, tipo de datos, presencia de asimetría, heterogeneidad *intra*-factor de los parámetros a estimar, entre otras), así como del grado en el que se representa adecuadamente el constructo evaluado. Y este último aspecto no puede ser considerado únicamente de manera analítica ya que se desconoce el valor poblacional del parámetro (por ejemplo, se puede obtener  $\hat{\lambda}_{ij} = 0,4$  tanto de  $\lambda_{ij} = 0,2$  como de  $\lambda_{ij} = 0,4$ ). Respecto a los estudios citados más arriba, poner

a prueba el modelo de independencia permite al investigador aplicado la utilización de una herramienta inferencial para contrastar si ciertos factores acumulan la suficiente cantidad de varianza común en cada muestra concreta.

Los métodos de estimación no parecen tener un efecto diferencial demasiado elevado. Con datos continuos, ULS permite estimar algunas soluciones que no son estimables mediante ML por problemas de convergencia y/o presencia de casos *Heywood*. Ximénez (2006, 2007) ya mostró esta ventaja de ULS frente a ML. No obstante, un resultado de interés obtenido en el presente trabajo es que ULS produce una tasa ligeramente mayor de soluciones T2 que ML. Por ejemplo, con  $\lambda_{ij} = 0,2$ ,  $n = 4$  y  $N = 200$  se produce un 42,5% de soluciones T2 utilizando ML y un 45,9% utilizando ULS (en Anexos), por lo que ULS produce un 3,9% menos de soluciones IM pero un 3,4% más de soluciones T2 en comparación con ML en las mismas condiciones. Con datos ordinales y dicotómicos, el método RML ha mostrado ser menos eficaz que los métodos RDWLS y RULS.

Las condiciones en las que se obtienen soluciones no convergentes y/o con presencia de casos *Heywood* (soluciones IM) suponen el extremo en el que se producen las mayores pérdidas de sensibilidad. Por tanto, el estudio de las condiciones en las que se producen las soluciones IM nos permite identificar escenarios de aplicación en los que el AFC es una técnica contraindicada. Obtener este tipo de soluciones no es accidental, por lo que es preciso superar esta prueba aislando al factor VCL con el fin de garantizar unos mínimos de sensibilidad (Gagné y Hancock, 2006). Por otro lado, las condiciones en las que predominan las soluciones estimadas con la suficiente precisión y en las que se rechaza  $H_0$  del modelo de independencia (en este estudio soluciones T1 en las que  $C_j \geq 0,92$ ), suponen el extremo contrario en cuanto a la sensibilidad de la técnica para detectar parámetros poblacionales verdaderos y con varianza común suficiente en las condiciones estudiadas. De esta manera, se puede establecer un

continuo que va desde el tipo de condiciones en las que se producen importantes problemas de estimación (soluciones IM) hasta el tipo de condiciones en las que estos problemas prácticamente desaparecen, obteniéndose factores con consistencia empírica y adecuado ajuste teórico.

La RPP indica que es frecuente utilizar entre 4 y 6 variables observables por factor. A esto hay que añadir que la mayoría de las veces se trabaja con datos ordinales o dicotómicos, y que una proporción no despreciable de aplicaciones se realizan sobre un número limitado de observaciones (44,2% de muestras con  $N \leq 200$  (Fabrigar et al., 1999), 18% de muestras con  $N \leq 100$  (MacCallum y Austin, 2000), 20,3% de muestras con  $N \leq 200$  (Jackson et al., 2006), mediana = 141 observaciones (Shah y Goldstein (2006))). Estas condiciones presentes en la práctica son las que han orientado el diseño de simulación propuesto en el presente trabajo. Pues bien, aunque no se pueden identificar con precisión las combinaciones concretas de todas estas fuentes de variación en la práctica convencional, los resultados obtenidos reflejan que el AFC no estaría indicado como técnica de pre-evaluación en parte de los factores propuestos en la literatura, especialmente si se tiene en cuenta la frecuente evaluación de modelos tentativos. Solamente la inspección de la proporción de soluciones IM obtenida en este trabajo reflejaría problemas de sensibilidad para identificar ciertos factores en parte de las condiciones en las que se está aplicando AFC, y esta situación parece estar pasando totalmente desapercibida.

Si nos concentramos en la condición  $n = 4$ , relativamente frecuente en la práctica, y promediando entre las estimaciones realizadas en los 4 niveles del tamaño muestral simulado (200, 300, 400 y 500), con datos ordinales y en condiciones de simetría se obtiene un 78,8% de soluciones T1 (52,5%), con resultados muy similares en la distribución uniforme: 78,7% (52,6%). En condiciones de asimetría se obtiene un 63,4% de T1 (28,5%), reduciéndose considerablemente el número de soluciones óptimas. Con datos dicotómicos se obtiene un

69,7% de T1 (33%) en condiciones de simetría, y un 62,1% (24,6%) en la condición más asimétrica. El número de soluciones óptimas con datos dicotómicos es bastante reducido incluso en situaciones de simetría.

Cuando los modelos se han simulado a partir de cargas poblacionales heterogéneas, los resultados mejoran pero solo ligeramente: datos ordinales – 77,3% soluciones T1 en condiciones de simetría (54,9%) y 63,5% T1 en condiciones de asimetría (30%); datos dicotómicos – 67,5% T1 en condiciones de simetría (34%) y 61,2% T1 en condiciones de asimetría (26,6%). Estos resultados vienen propiciados por la estimación de parámetros poblacionales entre 0,35 y 0,5 presentes en las simulaciones de cargas heterogéneas, si bien la existencia de cargas por debajo de 0,2 potencia la aparición de soluciones IM en este tipo de soluciones.

En la condición  $n = 5$  mejoran todos los resultados anteriores. Con valores fijos de  $\lambda_{ij}$ , los datos ordinales reflejan un 91,5% de soluciones T1 (66,1%) en condiciones de simetría y un 81% (35,1%) en condiciones de asimetría, y los datos dicotómicos un 85,1% (39%) con distribución simétrica y un 76,5% (28,5%) con datos asimétricos. Con cargas heterogéneas, los datos ordinales reflejan un 93,2% de soluciones T1 (76,3%) con simetría y un 80,7% (44,2%) con asimetría, y los datos dicotómicos un 85,2% (51,2%) con simetría y un 77,2% (36,5%) con asimetría. Toda esta información se ha elaborado a partir de las Tablas 7 a 10 del apartado 3.2.3 de resultados. Siguiendo el esquema de resultados propuesto, la información anterior proviene de aplicar el método de estimación ML a los datos continuos y el método de estimación RDWLS a los datos ordinales y dicotómicos. Nuevamente, los valores que aparecen entre paréntesis reflejan un importante descenso de la sensibilidad del AFC cuando existe asimetría en la distribución de los datos discretos, especialmente con datos dicotómicos. La capacidad del AFC para “capturar” adecuadamente el parámetro poblacional es bastante limitada en este tipo de



condiciones, con porcentajes inferiores al 40% en la mayoría de casos. Estos resultados son consistentes con la investigación previa (Forero et al., 2009), y se alinean con la recomendación de no utilizar ítems dicotómicos que no presenten cargas factoriales más elevadas que las aconsejados habitualmente (por ejemplo, utilizar  $\hat{\lambda}_{ij} \geq 0,4$ ), manteniendo al mismo tiempo unos mínimos en cuanto a número de indicadores por factor, tamaño muestral y simetría.

Todos estos resultados se han centrado en la estimación de modelos simulados a partir de cargas fijas  $\lambda_{ij} = 0,3$ , o en modelos simulados a partir de cargas heterogéneas cuyo promedio a nivel poblacional se encuentra en 0,3. Se trata de las condiciones en las que se producen las estimaciones más en el límite de lo que se considera como cargas salientes. Así, por ejemplo, con datos continuos (estimación ML) y  $n = 4$  el rango de valores promedio de todas las cargas estimadas oscila entre -0,3 y 0,44 (centil<sub>25-75</sub> = 0,29 - 0,34), con  $n = 5$  oscila entre -0,3 - 0,43 (centil<sub>25-75</sub> = 0,28 - 0,33), y con  $n = 6$  oscila entre -0,26 - 0,41 (centil<sub>25-75</sub> = 0,28 - 0,32). Con datos ordinales (estimación RDWLS) y distribución asimétrica, con  $n = 4$  el rango oscila entre -0,37 y 0,52 (centil<sub>25-75</sub> = 0,29 - 0,37), con  $n = 5$  oscila entre -0,37 y 0,49 (centil<sub>25-75</sub> = 0,28 - 0,35), y con  $n = 6$  entre -0,37 y 0,47 (centil<sub>25-75</sub> = 0,28 - 0,34). Con datos dicotómicos (estimación RDWLS) y distribución asimétrica, con  $n = 4$  el rango oscila entre -0,45 y 0,54 (centil<sub>25-75</sub> = 0,30 - 0,38), con  $n = 5$  oscila entre -0,36 y 0,51 (centil<sub>25-75</sub> = 0,28 - 0,35), y con  $n = 6$  entre -0,38 y 0,48 (centil<sub>25-75</sub> = 0,28 - 0,34).

En contraposición al uso generalizado de puntos de corte de los valores de  $\hat{\lambda}_{ij}$ , los hallazgos encontrados en este trabajo son consistentes con la estrategia de pre-evaluación propuesta: si el investigador aplicado se encuentra con valores estimados en torno a los comentados más arriba puede probar a realizar AFC sobre cada uno de los factores del modelo que puedan estar comprometidos. Si la solución resultante es de tipo IM o de tipo T2 ( $H_0$  modelo de independencia), entonces se debe considerar hasta qué punto las condiciones de aplicación

son adecuadas y si AFC es la técnica idónea para analizar los datos disponibles. Si la solución es de tipo T1 ( $H_1$  del modelo de independencia), se puede concluir que las condiciones de aplicación son adecuadas, aunque tal vez no sean óptimas. En cualquiera de estos dos escenarios, sería importante que los investigadores informasen de los valores de  $\chi^2_{\text{Null}}$  junto a los grados de libertad y nivel crítico asociados para que otros investigadores pudieran valorar el estatus o naturaleza teórica de los constructos evaluados y la adecuación de ciertas condiciones de aplicación.

Esta estrategia de análisis puede servir tanto para descartar el AFC como herramienta de trabajo como para dotar de consistencia empírica a ciertas variables latentes que son evaluadas en condiciones subóptimas, lo que puede ser de interés para investigadores aplicados que trabajan con submuestras cualificadas (población clínica, por ejemplo) y para los editores y revisores de revistas científicas como criterio para la aceptación de artículos. Además, utilizar esta estrategia potenciaría la comparación de modelos teóricos cualitativamente distintos. Si bien los resultados obtenidos en el presente trabajo plantean un escenario exigente para la obtención de soluciones T1 con ajuste teórico, también es cierto que existe cierta proporción de soluciones que superan todos los obstáculos, por así decir, y que podrían ser relevantes desde el punto de vista del constructo teórico. No obstante, no puede ni debe ser nuestra misión aconsejar u orientar sobre la conveniencia a nivel sustantivo de retener o rechazar este tipo de factores en la investigación aplicada. El planteamiento que aquí se desarrolla se refiere exclusivamente a la validación de la estrategia a seguir. En base a los hallazgos encontrados, esta estrategia de evaluación también podría servir para orientar el diseño de nuevos estudios e investigaciones, considerando las condiciones de aplicación que se deberían alcanzar antes del proceso de recogida de información.

Como se ha visto en este trabajo, los índices descriptivos de ajuste utilizados frecuentemente en la práctica convencional del AFC no son adecuados para evaluar sobreparametrización, salvo a excepción de CFI aunque de manera parcial. La obtención de una solución T1 en combinación con valores de CFI próximos a 1 y valores de ECVI, AIC y CAIC claramente superiores cuando se calculan sobre el modelo de independencia respecto al modelo evaluado, ofrecen ciertas evidencias de una adecuada recuperación de parámetros. Superados todos estos obstáculos, llega el momento de valorar la relevancia teórica del constructo estudiado, así como la posibilidad de profundizar en su naturaleza mediante estudios de invarianza con nuevas muestras y de validez predictiva. Existen otras estrategias de análisis que podrían ayudar a los investigadores aplicados y a los revisores a alcanzar el mismo objetivo que el planteado en el presente trabajo. Una de estas estrategias es el Análisis Paralelo (AP) el cual se basa en la proyección en un gráfico de sedimentación o *scree plot* de los autovalores obtenidos comparándolos con autovalores calculados a partir de un tipo de modelo nulo (es decir, calculados a partir de un conjunto de datos aleatorios en las mismas condiciones que los datos muestrales: mismo número de variables observables, mismo tamaño muestral). Otra posible técnica es la denominada *sensitivity analysis* (Byrne, Shavelson, y Muthén, 1989), que consiste en añadir parámetros menores en el modelo y observar cómo cambian las estimaciones entre ambas soluciones. Si las cargas factoriales no cambian cuando se incluyen estos parámetros menores o secundarios, el resultado puede considerarse como una evidencia de la robustez de la solución inicial. Otras técnicas de interés podrían ser las aproximaciones E/CFA y ESEM, mencionadas en el Capítulo 1. Por descontado, el foco en la naturaleza teórica de los constructos evaluados depende de la existencia de una teoría substantiva y de investigación previa, y todas estas estrategias podrían obtener resultados y decisiones convergentes en consonancia con el enfoque falsacionista, siempre y cuando no sean utilizadas como meras

técnicas estadísticas. Comparar los resultados que se obtendrían aplicando todas estas estrategias en las mismas condiciones excede con mucho el alcance del presente trabajo, si bien queremos plantear el interés que tendría realizar este tipo de investigación adicional.

En cuanto a las limitaciones del presente trabajo y posibles líneas de investigación a futuro conviene señalar en primer lugar que, dada la novedad que implica este trabajo, habría que profundizar en la evaluación del modelo de independencia en nuevas y más complejas condiciones. Especialmente, habría que poner el énfasis en comparar los resultados obtenidos con pre-evaluaciones de clústers simulados a partir de estructuras multidimensionales, bajo distintas condiciones, y también a partir de datos reales. Una importante limitación que tiene el trabajo aquí presentado es la fuerte dependencia que tiene el resultado de la prueba  $\chi^2_{\text{Null}}$  respecto a los valores de  $\hat{\lambda}_{ij}$ , por lo que ciertos niveles de sobreestimación podrían derivar en rechazos sistemáticos de la  $H_0$  del modelo de independencia. Esta situación puede darse con cierta frecuencia en contextos aplicados ya que es habitual encontrarnos con cierto nivel de *cross-loading*. En esta línea, habría también que contrastar qué ocurre cuando el factor evaluado proviene de una estructura multidimensional en la que existe relación entre factores, situación muy común en la investigación aplicada. Para abordar todas estas limitaciones parece relevante profundizar en los estudios de potencia, en combinación con la pre-evaluación del modelo de independencia. En este trabajo se ha presentado una primera aproximación en la que los resultados obtenidos muestran una elevada convergencia, si bien es verdad que obtener buenos resultados con un estudio de potencia es más exigente todavía que a través del test que pone a prueba la  $H_0$  nula del modelo de independencia, ya que se analiza parámetro a parámetro. En cualquier caso, todo ello requiere de investigación adicional.

Otras cuestiones y limitaciones a abordar en nuevos estudios se relacionan con las medidas de ajuste teórico y descriptivo utilizadas en el presente trabajo. No deja de ser un tanto

contradictorio que para elaborar estrategias de evaluación alternativas al uso de puntos de corte en los valores de *lambda*, se utilicen puntos de corte en otros *outputs*. En este trabajo todos los índices se han utilizado de forma orientativa, aunque quedaría trabajo por realizar con el fin de mejorar la *especificidad* de los análisis realizados, especialmente en el caso de ECVI por el potencial mostrado. Otro aspecto a considerar a futuro sería la realización de estudios en los que se definieran distintos niveles de significación alternativos a  $\alpha = 0,05$  en el contraste de la  $H_0$  del modelo de independencia (Error Tipo I) y evaluar cómo afecta a la sensibilidad de la técnica en distintas condiciones.

El propio concepto de modelo de independencia o modelo nulo no es un concepto cerrado e incontrovertible. Así, algunos autores como McDonald inciden en la cuestión de qué puede considerarse como un modelo nulo: “...*no compelling foundation has been offered for choosing a relative fit index over an absolute index, or for regarding uncorrelated variables as a null model*” (McDonald y Ho, 2002, p. 72). En este sentido, otros posibles modelos nulos o de independencia podrían ser puestos a prueba en la estrategia de pre-evaluación propuesta, fijando algunas de las cargas factoriales con valores distintos de cero, por ejemplo. Conviene señalar que, si bien otros autores (Bentler y Bonnett, 1980; Bentler, 1990) plantean que el modelo de independencia utilizado en este trabajo es el que parece tener más sentido desde un punto de vista aplicado, una línea de investigación a futuro podría estar relacionada con utilizar criterios base (o nulos) adicionales para la evaluación de la factorabilidad en mediante AFC. Por último, parece oportuno realizar un pequeño apunte sobre la línea a seguir desde un punto de vista teórico. A nuestro juicio, el concepto de *variable latente*, su naturaleza y sus implicaciones en la investigación aplicada requieren de una importante revisión y actualización en Psicología, en línea con las nuevas actualizaciones del concepto de causalidad.

## REFERENCIAS

## REFERENCIAS

- Abad, F. J., Olea, J., Ponsoda, V., & García, C. (2011). *Medición en ciencias sociales y de la salud*. Madrid: Síntesis.
- Barrett, P. (2007). Structural Equation Modelling: Adjudging Model Fit. *Personality and Individual Differences*, 42 (5), 815-24. doi:10.1016/j.paid.2006.09.018
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological Bulletin*, 107(2), 238-246. doi:10.1037/0033-2909.107.2.238
- Bentler, P. M., & Bonett, D. G. (1980). Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, 88(3), 588-606. doi:10.1037/0033-2909.88.3.588
- Bollen, K. A. (1989). *Structural equations with latent variables*. New York, NY: John Wiley & Sons.
- Bollen, K., A., & Hoyle, R. H. (2012). Latent variables in structural equation modeling. In R. H. Hoyle (Ed.), *Handbook of structural equation modeling* (pp. 56-67). Guilford Press.
- Boomsma, A. (2000). Reporting analyses of covariance structures. *Structural Equation Modeling*, 7(3), 461-483. doi:10.1207/S15328007SEM0703\_6
- Boomsma, A. (2013). Reporting Monte Carlo studies in structural equation modeling. *Structural Equation Modeling*, 20(3), 518-540. doi:10.1080/10705511.2013.797839
- Borsboom, D., Mellenbergh, G. J., & Van Heerden, J. (2003). The theoretical status of latent variables. *Psychological Review*, 110(2), 203-219. doi:10.1037/0033-295X.110.2.203

- Briggs, N. E., & MacCallum, R. C. (2003). Recovery of weak common factors by maximum likelihood and ordinary least squares estimation. *Multivariate Behavioral Research*, 38, 25-56. doi:10.1207/S15327906MBR3801\_2
- Brown, T. A. (2015). *Confirmatory factor analysis for applied research*. Guilford Publications.
- Byrne, B. M., Shavelson, R. J., & Muthén, B. (1989). Testing for the equivalence of factor covariance and mean structures: The issue of partial measurement invariance. *Psychological Bulletin*, 105, 456–466. doi:10.1037/0033-2909.105.3.456
- Cattell, R. B. (Ed.). (1978). *The scientific use of factor analysis in behavioral and life sciences*. Plenum Press, NY.
- Curran, P. J., West, S. G., & Finch, J. F. (1996). The robustness of test statistics to nonnormality and specification error in confirmatory factor analysis. *Psychological Methods*, 1(1), 16-29. doi:10.1037/1082-989X.1.1.16
- De Winter, J. C. F., Dodou, D., & Wieringa, P. A. (2009). Exploratory factor analysis with small sample sizes. *Multivariate Behavioral Research*, 44(2), 147-181. doi:10.1080/00273170902794206
- Enders, C. K., & Bandalos, D. L. (2001). The relative performance of full information maximum likelihood estimation for missing data in structural equation models. *Structural Equation Modeling*, 8(3), 430-457. doi:10.1207/S15328007SEM0803\_5
- Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, E. J. (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods*, 4(3), 272-299. doi:10.1037/1082-989X.4.3.272
- Fan, X., & Sivo, S.A. (2005). Sensitivity of fit indices to misspecified structural or measurement model components: rationale of two-index strategy revisited. *Structural Equation Modeling*, 12(3), 343-367. doi:10.1207/s15328007sem1203\_1



- Fan, X., & Sivo, S.A. (2007). Sensitivity of fit indices to model misspecification and model types. *Multivariate Behavioral Research*, 42(3), 509-529. doi:10.1080/00273170701382864
- Ferrando, P.J., & Anguiano-Carrasco, C. (2010). El análisis factorial como técnica de investigación en Psicología. *Papeles del Psicólogo*, 31(1), 18-33. Descargado de <http://www.papelesdelpsicologo.es/pdf/1793.pdf>
- Ferrando, P. J., & Lorenzo-Seva, U. (2000). Unrestricted versus restricted factor analysis of multidimensional test items: Some aspects of the problem and some suggestions. *Psicológica*, 21(3), 301-324. Descargado de <http://www.uv.es/revispsi/articulos3.00/ferran7.pdf>
- Forero, C.G., Maydeu-Olivares, A., & Gallardo-Pujol, D. (2009). Factor analysis with ordinal indicators: A Monte Carlo study comparing DWLS and ULS estimation. *Structural Equation Modeling*, 16, 625–641. doi:10.1080/10705510903203573
- Gagné, P., & Hancock, G. R. (2006). Measurement model quality, sample size, and solution propriety in confirmatory factor models. *Multivariate Behavioral Research*, 41(1), 65-83. doi:10.1207/s15327906mbr4101\_5
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis*. Pearson. Upper Saddle River, NJ.
- Harlow, L. L. (2005). Making meaning of multivariate methods. In A. Maydeu-Olivares, & J. McArdle (Eds.), *Contemporary psychometrics* (pp. 537-572). Psychology Press.
- Heene, M., Hilbert, S., Draxler, C., Ziegler, M., & Bühner, M. (2011). Masking misfit in confirmatory factor analysis by increasing unique variances: a cautionary note on the usefulness of cutoff values of fit indices. *Psychological Methods*, 16(3), 319-336. doi:10.1037/a0024917

- Hu, L., & Bentler, P.M. (1998). Fit indices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological Methods*, 3, 424-453. doi:10.1037/1082-989X.3.4.424
- Hu, L., & Bentler, P.M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6, 1-55. doi:10.1080/10705519909540118
- Izquierdo, I., Olea, J., & Abad, F. J. (2014). Exploratory factor analysis in validation studies: Uses and recommendations. *Psicothema*, 26(3), 395-400. doi:10.7334/psicothema2013.349
- Jackson, D. L., Gillasp, Jr, J. A., & Purc-Stephenson, R. (2009). Reporting practices in confirmatory factor analysis: an overview and some recommendations. *Psychological Methods*, 14(1), 6-23. doi:10.1037/a0014694
- Jöreskog, K. G. (1969). A general approach to confirmatory maximum likelihood factor analysis. *Psychometrika*, 34(2), 183-202. doi:10.1007/BF02289343
- Jöreskog, K. G. (1990). New developments in LISREL: Analysis of ordinal variables using polychoric correlations and weighted least squares. *Quality and Quantity*, 24, 387- 404. doi:10.1007/BF00152012
- Jöreskog, K. G. (1993). Testing structural equation models. In K. A. Bollen, & J. S. Long (Eds.), *Testing Structural Equation Models* (pp. 294-316). Newbury Park, CA: Sage.
- Jöreskog, K. G. (1994). On the estimation of polychoric correlations and their asymptotic covariance matrix. *Psychometrika* 59, 381-389. doi:10.1007/BF02296131
- Jöreskog, K. G. (2004). *On chi-squares for the independence model and fit measures in LISREL*. Descargado de [www.ssicentral.com/lisrel/techdocs/ftb.pdf](http://www.ssicentral.com/lisrel/techdocs/ftb.pdf)

- Jöreskog, K. G., & Lawley, D. N. (1967). New Methods in Maximum Likelihood Factor Analysis. *ETS Research Bulletin Series*, 1967(2), i-24. doi:10.1002/j.2333-8504.1967.tb00703.x
- Jöreskog, K. G., & Sörbom, D. (1979). *Advances in factor analysis and structural equation models* (J. Magidson, ed.). Cambridge, Mass.: Abt Books.
- Jöreskog, K. G., & Sörbom, D. (1993). *LISREL 8: Structural equation modeling with the SIMPLIS command language*. Scientific Software International.
- Jöreskog, K.G., & Sörbom, D. (1996a). *LISREL 8: User's reference guide* (2nd ed.). Lincolnwood, IL: Scientific Software International.
- Jöreskog, K.G., & Sörbom, D. (1996b). *PRELIS 2: User's reference guide* (3rd ed.). Chicago, IL: Scientific Software International.
- Jöreskog, K. G., Sörbom, D., & Du Toit, S. H. C. (2001). *LISREL 8: New statistical features*. Scientific Software International.
- Kaplan, D. (1988). The impact of specification error on the estimation, testing, and improvement of structural equation models. *Multivariate Behavioral Research*, 23(1), 69-86. doi:10.1207/s15327906mbr2301\_4
- Kaplan, D. (1989). A study of the sampling variability and z-values of parameter estimates from misspecified structural equation models. *Multivariate Behavioral Research*, 24(1), 41-57. doi:10.1207/s15327906mbr2401\_3
- Kaplan, D. (2008). *Structural equation modeling: Foundations and extensions*. Sage Publications.
- Kline, R. B. (1994). *An easy guide to factor analysis*. Routledge.
- Kline, R. B. (2010). *Principles and practice of structural equation modeling* (3rd ed.). New York: Guilford Press.

- Kline, R. B. (2015). *Principles and practice of structural equation modeling*. Guilford Publications.
- Kruyen, P. M., Emons, W. H., & Sijtsma, K. (2013). On the shortcomings of shortened tests: A literature review. *International Journal of Testing*, 13(3), 223-248. doi:10.1080/15305058.2012.703734
- Levine, M.S. (1977). *Canonical correlation analysis and factor comparison techniques*. Sage, Beverly Hills.
- Little, T. D., Lindenberger, U., & Nesselroade, J. R. (1999). On selecting indicators for multivariate measurement and modeling with latent variables: When "good" indicators are bad and "bad" indicators are good. *Psychological Methods*, 4(2), 192-211. doi:10.1037/1082-989X.4.2.192
- Lord, F. M., & Novick, M. R. (1968). *Statistical theories of mental test scores*. Reading, MA: Addison Wesley.
- MacCallum, R. C., & Austin, J. T. (2000). Applications of Structural Equation Modeling in Psychological Research. *Annual Review of Psychology*, 51(1), 201-226. doi:10.1146/annurev.psych.51.1.201
- MacCallum, R. C., Browne, M. W., & Sugawara, H. M. (1996). Power analysis and determination of sample size for covariance structure modeling. *Psychological Methods*, 1(2), 130-149. doi:10.1037/1082-989X.1.2.130
- MacCallum, R. C., Tucker, L. R., & Briggs, N. E. (2001). An alternative perspective on parameter estimation in factor analysis and related methods. In R. Cudeck, S. du Toit, & D. Sörbom (Eds.), *Structural equation modeling: Present and future* (pp. 39-57). Lincolnwood, IL: Scientific Software International, Inc.

- MacCallum, R. C., Widaman, K. F., Zhang, S., & Hong, S. (1999). Sample size in factor analysis. *Psychological Methods*, 4(1), 84-99. doi:10.1037/1082-989X.4.1.84
- Martínez-Arias, R., Castellanos, M. A., & Chacón, J. C. (2014). *Métodos de investigación en Psicología*. Madrid, EOS Universitaria.
- Marsh, H. W., Balla, J. R., & McDonald, R. P. (1988). Goodness-of-fit indexes in confirmatory factor analysis: The effect of sample size. *Psychological Bulletin*, 103(3), 391-410. doi:10.1037/0033-2909.103.3.391
- Marsh, H. W., Hau, K. T., Balla, J. R., & Grayson, D. (1998). Is more ever too much? The number of indicators per factor in confirmatory factor analysis. *Multivariate behavioral research*, 33(2), 181-220. doi:10.1207/s15327906mbr3302\_1
- Marsh, H. W., Hau, K., & Grayson, D. (2005). Goodness of fit in structural equation models. In A. Maydeu-Olivares, & J. J. McArdle (Eds.), *Contemporary psychometrics* (pp. 275-340). Psychology Press.
- McCrae, R. R., Zonderman, A. B., Costa Jr, P. T., Bond, M. H., & Paunonen, S. V. (1996). Evaluating replicability of factors in the Revised NEO Personality Inventory: Confirmatory factor analysis versus Procrustes rotation. *Journal of Personality and Social Psychology*, 70(3), 552-566. doi:10.1037/0022-3514.70.3.552
- McDonald, R. P. (1999). *Test theory: A unified treatment*. Lawrence Erlbaum Associates.
- McDonald, R. P., & Ho, M. H. R. (2002). Principles and practice in reporting structural equation analyses. *Psychological Methods*, 7(1), 64-82. doi:10.1037/1082-989X.7.1.64
- Millsap, R. E. (2005). Four unresolved problems in studies of factorial invariance. In A. Maydeu-Olivares, & J. J. McArdle (Eds.), *Contemporary psychometrics* (pp. 153-172). Psychology Press.

- Mundfrom, D. J., Shaw, D. G., & Ke, T. L. (2005). Minimum sample size recommendations for conducting factor analyses. *International Journal of Testing*, 5(2), 159-168. doi:10.1207/s15327574ijt0502\_4
- Mulaik, S. A. (1986). Toward a synthesis of deterministic and probabilistic formulations of causal relations by the functional relation concept. *Philosophy of Science*, 313-332. doi:10.1086/289320
- Mulaik, S. A. (1993). Objectivity and multivariate statistics. *Multivariate Behavioral Research*, 28(2), 171-203. doi:10.1207/s15327906mbr2802\_2
- Mulaik, S. A. (2009) *Linear Causal Modeling with Structural Equations*. Boca Raton FL, CRC Press, Taylor and Francis Group.
- Muthén, B. O. (1978). Contributions to factor analysis of dichotomous variables. *Psychometrika*, 43, 551-560. doi:10.1007/BF02293813
- Muthén, B. O. (1984). A general structural equation model with dichotomous, ordered categorical, and continuous latent variable indicators. *Psychometrika*, 49, 115-132. doi:10.1007/BF02294210
- Muthén, B. O. (1993). Goodness of fit with categorical and other nonnormal variables. In K. A. Bollen, & J. S. Long (Eds.), *Testing Structural Equation Models* (pp. 205-234). Newbury Park, CA: Sage.
- Muthén, B. O., & Kaplan, D. (1992). A comparison of some methodologies for the factor analysis of non-normal Likert variables: A note on the size of the model. *British Journal of Mathematical and Statistical Psychology*, 45(1), 19-30. Doi:10.1111/j.2044-8317.1992.tb00975.x

- Muthén, L. K., & Muthén, B. O. (2002). How to use a Monte Carlo study to decide on sample size and determine power. *Structural Equation Modeling*, 9(4), 599-620. doi:10.1207/S15328007SEM0904\_8
- Olsson, U.H., Foss, T., Troye, S. V., & Howell, R. D. (2000). The Performance of ML, GLS and WLS Estimation in Structural Equation Modeling Under Conditions of Misspecification and Nonnormality. *Structural Equation Modeling*, 7 (4), 557-595. doi:10.1207/S15328007SEM0704\_3
- Satorra, A., & Saris, W. E. (1985). Power of the likelihood ratio test in covariance structure analysis. *Psychometrika*, 50, 83-90. doi:10.1007/BF02294150
- Schermelleh-Engel, K., Moosbrugger, H., & Müller, H. (2003). Evaluating the fit of structural equation models: Tests of significance and descriptive goodness-of-fit measures. *Methods of Psychological Research Online*, 8(2), 23-74. Descargado de <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.509.4258&rep=rep1&type=pdf>
- Shah, R., & Goldstein, S. M. (2006). Use of structural equation modeling in operations management research: Looking back and forward. *Journal of Operations Management*, 24(2), 148-169. doi:10.1016/j.jom.2005.05.001
- Shaughnessy, J. J., Zechmeister, E. B., Zechmeister, J. S., & Barroso, C. B. D. (2007). *Métodos de investigación en Psicología*. McGraw-Hill Interamericana.
- Simon, H. A. (1954). Spurious correlation: A causal interpretation\*. *Journal of the American Statistical Association*, 49(267), 467-479. doi:10.1080/01621459.1954.10483515
- Skrondal, A. (2000). Design and analysis of Monte Carlo experiments: attacking the conventional wisdom. *Multivariate Behavioral Research*, 35, 137-167. doi:10.1207/S15327906MBR3502\_1

- Skrondal, A., & Rabe-Hesketh, S. (2004). *Generalized latent variable modeling: Multilevel, longitudinal, and structural equation models*. Crc Press.
- Stevens, J. (2002). *Applied multivariate statistics for the social sciences*. Mahwah, NJ: Lawrence Erlbaum Associates.
- Thurstone, L. L. (1947). *Multiple factor analysis*. Chicago: University of Chicago Press.
- Trochim, W. M. K. (2001). *The research methods knowledge base*. Cincinnati, OH: Atomic Doc Publishing.
- Tucker, L.R. (1951). A method for synthesis of factor analysis studies. *Personnel Research Section Report*, 984. Washington, D. C.: Department of the Army (120 pages). Descargado de <http://www.dtic.mil/cgi-bin/GetTRDoc?AD=AD0047524>
- Tucker, L.R., & Lewis, C. (1973). A reliability coefficient for maximum likelihood factor analysis. *Psychometrika*, 38, 1-10. doi:10.1007/BF02291170
- Velicer, W. F., & Fava, J. L. (1998). Effects of variable and subject sampling on factor pattern recovery. *Psychological Methods*, 3(2), 231-251. doi:10.1037/1082-989X.3.2.231
- West, S. G., & Koch, T. (2014). Restoring Causal Analysis to Structural Equation Modeling. Review of Causality: Models, Reasoning, and Inference, by Judea Pearl: New York, NY: Cambridge University Press, 484 pp. *Structural Equation Modeling*, 21(1), 161-166. doi:10.1080/10705511.2014.856700
- Wolf, E. J., Harrington, K. M., Clark, S. L., & Miller, M. W. (2013). Sample size requirements for structural equation models an evaluation of power, bias, and solution propriety. *Educational and Psychological Measurement*, 73(6), 913-934. doi:10.1177/0013164413495237



- Wothke, W. (1993). Nonpositive definite matrices in structural modeling. In K. A. Bollen & J. S. Long (Eds.), *Testing structural equation models* (pp. 256-293). Newbury Park, CA: Sage.
- Ximénez, C. (2006). A Monte Carlo Study of Recovery of weak factor loadings in Confirmatory Factor Analysis. *Structural Equation Modeling*, 13, 587-614. doi:10.1207/s15328007sem1304\_5
- Ximénez, C. (2007). Effect of variable and subject sampling on recovery of weak factors in CFA. *Methodology*, 3, 67-80. doi:10.1027/1614-2241.3.2.67
- Ximénez, C. (2009). Recovery of weak factor loadings in confirmatory factor analysis under conditions of model misspecification. *Behavior Research Methods*, 41, 1038-1052. doi:10.3758/BRM.41.4.1038
- Ximénez, C. (2016). Recovery of weak factor loadings when adding the mean structure in confirmatory factor analysis: A simulation study. *Frontiers in Psychology*, 6:1943. doi: 10.3389/fpsyg.2015.01943
- Yang-Wallentin, F., Jöreskog, K. G., & Luo, H. (2010) Confirmatory Factor Analysis of Ordinal Variables With Misspecified Models. *Structural Equation Modeling*, 17(3), 392-423. doi:10.1080/10705511.2010.489003
- Yuan, K. H. (2005). Fit indices versus test statistics. *Multivariate Behavioral Research*, 40(1), 115-148. doi:10.1207/s15327906mbr4001\_5

# ANEXOS

## ANEXOS

### A. Ejemplos de sintaxis

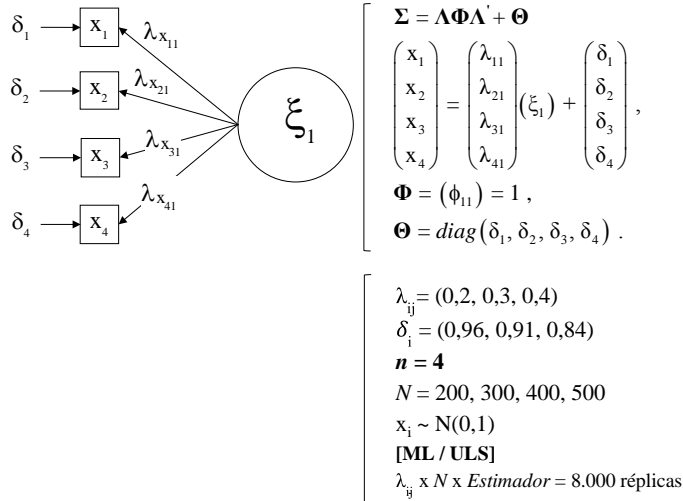
Ejemplos de sintaxis PRELIS/LISREL utilizada en el proceso de simulación y ajuste de modelos

<p><b>DATOS CONTINUOS</b></p> <p><math>\lambda_{ij} = 0,3, n = 4</math> y <math>N = 500</math></p> <p><b>Simulación de datos (PRELIS)</b></p> <p>DA NO=500 RP=1000  NE F1=NRAND  NE V1=0.3*F1+0.9539*NRAND  NE V2=0.3*F1+0.9539*NRAND  NE V3=0.3*F1+0.9539*NRAND  NE V4=0.3*F1+0.9539*NRAND  SD F1  CO ALL  OU RA='C:\[Ruta]\L030n4N500.DAT'</p> <p><b>Matriz var.-covarianzas (PRELIS)</b></p> <p>DA NI=4 NO=500 RP=1000  RA='C:\[Ruta]\L030n4N500.DAT'  CO ALL  OU MA=CM CM='C:\[Ruta]\L030n4N500.CM'</p> <p><b>Estimación (LISREL)</b></p> <p>DA NI=4 MA=CM NO=500 RP=1000  KM='C:\[Ruta]\L030n4N500.CM'  MO NX=4 NK=1  FR LX(1,1) LX(2,1) LX(3,1) LX(4,1)  OU AD=OFF  PV='C:\[Ruta]\L030n4N500.PV'  SV='C:\[Ruta]\L030n4N500.SV'  GF='C:\[Ruta]\L030n4N500.GF'  ME=ML (ULS a partir de las matrices L030n4N500.KM)</p>	<p><b>DATOS ORDINALES (5 categorías)</b></p> <p><math>\lambda_{ij} = 0,3, n = 4</math> y <math>N = 500</math> (5D1)</p> <p><b>Simulación de datos (PRELIS)</b></p> <p>DA NO=500 RP=1000  NE F1=NRAND  NE V1=0.3*F1+0.9539*NRAND  NE V2=0.3*F1+0.9539*NRAND  NE V3=0.3*F1+0.9539*NRAND  NE V4=0.3*F1+0.9539*NRAND  SD F1  RE V1-V6 OLD=-100 - -1.64485362695147,-1.64485362695146  - -0.674489750196082,-0.674489750196081 -  0.674489750196082,0.674489750196083 -  1.64485362695147,1.64485362695148 - 100 NEW=1,2,3,4,5  OR ALL  OU RA='C:\[Ruta]\L030n4N500.RAW'</p> <p><b>Matriz policóricas (PRELIS)</b></p> <p>DA N=4 NO=500 RP=1000  RA='C:\[Ruta]\L030n4N500.RAW'  OR ALL  OU MA=PM PM='C:\[Ruta]\L030n4N500.PM'  AC='C:\[Ruta]\L030n4N500.ACP'</p> <p><b>Estimación (LISREL)</b></p> <p>DA NI=4 MA=PM NO=500 RP=1000  CM='C:\[Ruta]\L030n4N500.PM'  AC='C:\[Ruta]\L030n4N500.ACP'  MO NX=4 NK=1  FR LX(1,1) LX(2,1) LX(3,1) LX(4,1)  OU AD=OFF  PV='C:\[Ruta]\L030n4N500.PV'  SV='C:\[Ruta]\L030n4N500.SV'  GF='C:\[Ruta]\L030n4N500.GF'  ME=ML/DWLS/ULS (estimadores robustos: RULS, RML y RDWLS))</p>
--	--

## B. Datos continuos (distribución normal)

### Ficha 1. Modelos simulados y síntesis de resultados ( $n = 4$ )

**Cuadro 1.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 1.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%)

$\lambda_{ij}$	$N$	$ML (n = 4)$			$ULS (n = 4)$		
		IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$	IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$
0,2	200	47,9%	42,5%	9,6%	44,0%	45,9%	10,1%
	300	45,1%	40,2%	14,7%	40,8%	44,0%	15,2%
	400	40,1%	39,9%	20,0%	35,9%	43,2%	20,9%
	500	35,0%	39,4%	25,6%	31,6%	41,6%	26,8%
0,3	200	17,9%	28,5%	53,6%	14,6%	29,5%	55,9%
	300	8,8%	15,0%	76,2%	6,7%	15,5%	77,8%
	400	3,6%	8,5%	87,9%	2,6%	9,0%	88,4%
	500	1,6%	4,5%	93,9%	1,0%	4,5%	94,5%
0,4	200	0,8%	2,0%	97,2%	0,6%	2,1%	97,3%
	300	0,2%	0,4%	99,4%	0,1%	0,4%	99,5%
	400	0,0%	0,3%	99,7%	0,0%	0,3%	99,7%
	500	0,0%	0,2%	99,8%	0,0%	0,2%	99,8%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 1.2.** Ajuste teórico en función del resultado del test  $\chi^2_{\text{Null}} (\alpha = 0,05)$ .  $\lambda_{ij} \times N$ , estimación ML (Media (D.T.))

$\lambda_{ij}$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (n = 4)$					$\hat{\Sigma}_0 (n = 4)$				
			T2	$C_j$	$RMSE_j$	$ARB_j$	$AMSE_j$	T1	$C_j$	$RMSE_j$	$ARB_j$	$AMSE_j$
0,2	200	52,1%	42,5%	,65 (.42)	,22 (.11)	,17 (.09)	1,08 (.54)	9,6%	,78 (.32)	,23 (.09)	,19 (.07)	1,17 (.45)
	300	54,9%	40,2%	,72 (.34)	<b>,18 (.09)</b>	,14 (.07)	,90 (.45)	14,7%	,82 (.28)	,20 (.08)	,15 (.06)	,98 (.39)
	400	59,9%	39,9%	,75 (.33)	<b>,17 (.09)</b>	,13 (.07)	,84 (.47)	20,0%	,88 (.09)	<b>,17 (.06)</b>	,13 (.04)	,83 (.32)
	500	65,0%	39,4%	,78 (.28)	<b>,15 (.08)</b>	,13 (.07)	,76 (.42)	25,6%	,87 (.18)	<b>,15 (.07)</b>	,12 (.05)	,77 (.36)
0,3	200	82,1%	28,5%	,85 (.22)	<b>,16 (.09)</b>	,13 (.08)	,53 (.30)	53,6%	<b>,92 (.12)</b>	<b>,15 (.07)</b>	,12 (.05)	,50 (.22)
	300	91,2%	15,0%	,88 (.10)	<b>,14 (.07)</b>	,12 (.07)	,48 (.24)	76,2%	<b>,93 (.06)</b>	<b>,12 (.06)</b>	<b>,10 (.05)</b>	,41 (.19)
	400	96,4%	8,5%	,91 (.08)	<b>,13 (.06)</b>	,11 (.05)	,42 (.20)	87,9%	<b>,94 (.05)</b>	<b>,11 (.05)</b>	<b>,09 (.04)</b>	,36 (.16)
	500	98,4%	4,5%	<b>,92 (.07)</b>	<b>,12 (.05)</b>	,10 (.05)	,40 (.16)	93,9%	<b>,95 (.05)</b>	<b>,10 (.04)</b>	<b>,08 (.04)</b>	,33 (.14)
0,4	200	99,2%	2,0%	<b>,92 (.08)</b>	<b>,15 (.07)</b>	,13 (.07)	,38 (.17)	97,2%	<b>,96 (.07)</b>	<b>,11 (.05)</b>	<b>,09 (.04)</b>	,28 (.12)
	300	99,8%	0,4%	<b>,96 (.02)</b>	<b>,12 (.03)</b>	,11 (.03)	,30 (.07)	99,4%	<b>,97 (.03)</b>	<b>,09 (.04)</b>	<b>,08 (.03)</b>	,23 (.10)
	400	100,0%	0,3%	<b>,99 (.01)</b>	<b>,07 (.03)</b>	<b>,06 (.03)</b>	,17 (.08)	99,7%	<b>,98 (.02)</b>	<b>,08 (.03)</b>	<b>,07 (.03)</b>	,19 (.08)
	500	100,0%	0,2%	<b>,98 (.00)</b>	<b>,07 (.01)</b>	<b>,06 (.00)</b>	,17 (.02)	99,8%	<b>,99 (.01)</b>	<b>,07 (.03)</b>	<b>,06 (.02)</b>	,17 (.07)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSE_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

Soluciones estimadas mediante ML.

**Tabla 1.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 4)$				$\hat{\Sigma}_0 (n = 4)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
0,2	200	<b>,90 (,690)</b>	,82 (,16)	,88 (,16)	,62 (,05)	<b>2,16 (,470)</b>	<b>1,31 (,19)</b>	<b>1,36 (,22)</b>	,79 (,07)
	300	<b>,90 (,688)</b>	,83 (,15)	,89 (,15)	,62 (,04)	<b>1,96 (,475)</b>	<b>1,34 (,21)</b>	<b>1,39 (,23)</b>	,79 (,07)
	400	<b>1,01 (,663)</b>	,87 (,15)	,93 (,15)	,63 (,04)	<b>1,82 (,512)</b>	<b>1,37 (,22)</b>	<b>1,43 (,24)</b>	,78 (,07)
	500	<b>,96 (,674)</b>	,89 (,15)	,95 (,15)	,63 (,04)	<b>1,92 (,504)</b>	<b>1,42 (,23)</b>	<b>1,48 (,26)</b>	,79 (,07)
0,3	200	<b>,88 (,687)</b>	,92 (,13)	,99 (,14)	,66 (,04)	<b>1,76 (,525)</b>	<b>1,55 (,34)</b>	<b>1,62 (,37)</b>	,88 (,12)
	300	<b>,84 (,695)</b>	,96 (,12)	<b>1,03 (,14)</b>	,66 (,04)	<b>1,83 (,519)</b>	<b>1,70 (,44)</b>	<b>1,77 (,46)</b>	,91 (,14)
	400	<b>,90 (,692)</b>	,96 (,13)	<b>1,04 (,14)</b>	,66 (,04)	<b>1,87 (,515)</b>	<b>1,91 (,51)</b>	<b>2,00 (,54)</b>	,96 (,16)
	500	<b>1,00 (,662)</b>	<b>1,03 (,08)</b>	<b>1,10 (,09)</b>	,67 (,02)	<b>1,88 (,513)</b>	<b>2,15 (,61)</b>	<b>2,25 (,65)</b>	<b>1,02 (,18)</b>
0,4	200	<b>1,17 (,639)</b>	,98 (,10)	<b>1,05 (,10)</b>	,68 (,03)	<b>1,79 (,531)</b>	<b>2,42 (,71)</b>	<b>2,53 (,76)</b>	<b>1,19 (,25)</b>
	300	<b>,31 (,858)</b>	<b>1,04 (,00)</b>	<b>1,15 (,00)</b>	,70 (,00)	<b>1,86 (,521)</b>	<b>3,22 (,91)</b>	<b>3,38 (,97)</b>	<b>1,42 (,30)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>1,94 (,509)</b>	<b>4,08 (1,04)</b>	<b>4,27 (1,12)</b>	<b>1,66 (,32)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>1,97 (,504)</b>	<b>4,92 (1,20)</b>	<b>5,15 (1,30)</b>	<b>1,89 (,36)</b>

$\chi^2_0 (p-v)$  - Media (nivel crítico).

$ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ ;  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.

Soluciones estimadas mediante ML.

**Tabla 1.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 4)$						$\hat{\Sigma}_0 (n = 4)$					
		$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$	$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$
0,2	200	<b>,00 (,01)</b>	<b>,02 (,00)</b>	,86 (,11)	,84 (**)	,59 (,34)	,55 (,48)	<b>,03 (,04)</b>	<b>,03 (,01)</b>	,86 (,12)	1,12 (,64)	,59 (,38)	,91 (,16)
	300	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,87 (,11)	1,3 (**)	,61 (,33)	,59 (,47)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,88 (,09)	1,11 (,47)	,64 (,28)	,94 (,10)
	400	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,87 (,11)	1,5 (**)	,61 (,33)	,69 (,44)	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,89 (,09)	1,17 (,47)	,68 (,29)	<b>,95 (,10)</b>
	500	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,88 (,09)	1,6 (**)	,65 (,29)	,73 (,42)	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,90 (,09)	1,15 (,44)	,69 (,28)	<b>,95 (,09)</b>
0,3	200	<b>,00 (,01)</b>	<b>,02 (,00)</b>	,89 (,09)	1,9 (**)	,68 (,29)	,82 (,37)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,91 (,08)	1,15 (,37)	,73 (,24)	<b>,96 (,07)</b>
	300	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,91 (,07)	1,9 (7,2)	,72 (,24)	,91 (,27)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,92 (,07)	1,12 (,35)	,75 (,23)	<b>,97 (,07)</b>
	400	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,91 (,08)	1,9 (**)	,72 (,25)	,88 (,30)	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,93 (,06)	1,09 (,29)	,79 (,20)	<b>,97 (,06)</b>
	500	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,91 (,08)	1,8 (1,68)	,72 (,25)	<b>,98 (,08)</b>	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,94 (,06)	1,08 (,26)	,81 (,18)	<b>,97 (,05)</b>
0,4	200	<b>,01 (,02)</b>	<b>,02 (,01)</b>	,89 (,10)	1,8 (8,71)	,67 (,31)	,88 (,28)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,95 (,05)	1,08 (,21)	,84 (,16)	<b>,98 (,04)</b>
	300	<b>,00 (,00)</b>	<b>,01 (,00)</b>	,97 (,00)	2,1 (,00)	,91 (,00)	<b>1,0 (,00)</b>	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,96 (,04)	1,05 (,14)	,89 (,12)	<b>,99 (,03)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,02 (,02)</b>	<b>,02 (,00)</b>	,97 (,03)	1,03 (,10)	,91 (,09)	<b>,99 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,01 (,00)</b>	,98 (,02)	1,02 (,08)	,93 (,08)	<b>,99 (,02)</b>

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

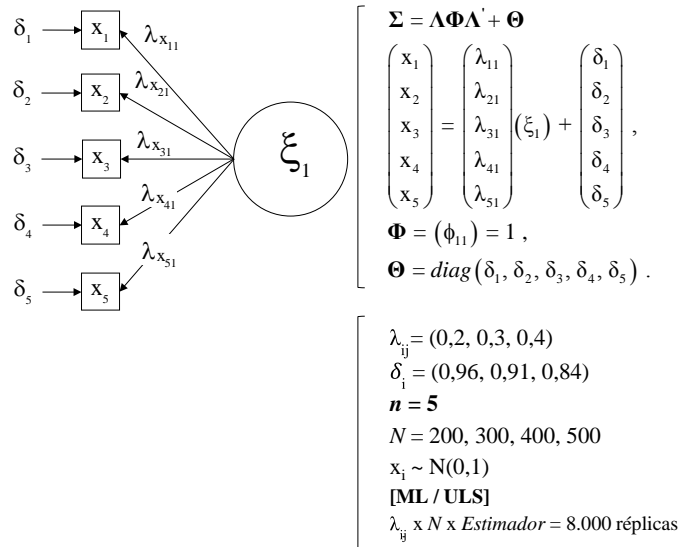
<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T.  $> 10$ .

n.a. - No aplicable.

Soluciones estimadas mediante ML.

Ficha 2. Modelos simulados y síntesis de resultados ( $n = 5$ )

**Cuadro 2.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 2.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%)

$\lambda_{ij}$	$N$	$ML (n = 5)$			$ULS (n = 5)$		
		IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$	IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$
0,2	200	39,6%	46,9%	13,5%	34,2%	51,5%	14,3%
	300	34,1%	45,6%	20,3%	28,4%	49,5%	22,1%
	400	29,9%	39,7%	30,4%	24,8%	43,5%	31,7%
	500	24,3%	37,9%	37,8%	19,8%	40,7%	39,5%
0,3	200	8,2%	20,2%	71,6%	4,4%	21,4%	74,2%
	300	1,9%	7,9%	90,2%	1,2%	8,0%	90,8%
	400	0,9%	2,1%	97,0%	0,7%	2,2%	97,1%
	500	0,4%	0,6%	99,0%	0,3%	0,6%	99,1%
0,4	200	0,0%	0,2%	99,8%	0,0%	0,2%	99,8%
	300	0,0%	0,0%	100%	0,0%	0,0%	100%
	400	0,0%	0,0%	100%	0,0%	0,0%	100%
	500	0,0%	0,0%	100%	0,0%	0,0%	100%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 2.2.** Ajuste teórico en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).  $\lambda_{ij} \times N$ , estimación ML (Media (D.T.))

$\lambda_{ij}$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (n = 5)$					$\hat{\Sigma}_0 (n = 5)$				
			T2	$C_j$	$RMSE_j$	$ARB_j$	$AMSE_j$	T1	$C_j$	$RMSE_j$	$ARB_j$	$AMSE_j$
0,2	200	60,4%	46,9%	,61 (.44)	,22 (.10)	,17 (.08)	1,08 (.52)	13,5%	,69 (.45)	,23 (.10)	,18 (.09)	1,15 (.49)
	300	65,9%	45,6%	,70 (.33)	<b>,18 (.09)</b>	,14 (.07)	,90 (.44)	20,3%	,83 (.25)	<b>,17 (.07)</b>	,13 (.05)	,86 (.34)
	400	70,1%	39,7%	,74 (.34)	<b>,16 (.09)</b>	,13 (.07)	,78 (.43)	30,4%	,84 (.24)	<b>,15 (.07)</b>	,12 (.05)	,76 (.34)
	500	75,7%	37,9%	,78 (.29)	<b>,14 (.08)</b>	,11 (.06)	,68 (.38)	37,8%	,88 (.12)	<b>,13 (.05)</b>	,10 (.04)	,64 (.25)
0,3	200	91,8%	20,2%	,83 (.24)	<b>,16 (.08)</b>	,14 (.08)	,53 (.28)	71,6%	,91 (.15)	<b>,14 (.06)</b>	,11 (.05)	,45 (.20)
	300	98,1%	7,9%	,90 (.07)	<b>,13 (.05)</b>	,11 (.05)	,44 (.16)	90,2%	<b>,94 (.07)</b>	<b>,11 (.04)</b>	<b>,09 (.04)</b>	,36 (.14)
	400	99,1%	2,1%	,84 (.35)	<b>,14 (.09)</b>	,12 (.09)	,47 (.30)	97,0%	<b>,95 (.04)</b>	<b>,09 (.03)</b>	<b>,08 (.03)</b>	,31 (.11)
	500	99,6%	0,6%	,88 (.12)	<b>,14 (.07)</b>	,12 (.06)	,47 (.22)	99,0%	<b>,96 (.03)</b>	<b>,08 (.03)</b>	<b>,07 (.03)</b>	,27 (.10)
0,4	200	100,0%	0,2%	<b>,97 (.01)</b>	<b>,14 (.00)</b>	,13 (.00)	,36 (.00)	99,8%	<b>,97 (.02)</b>	<b>,10 (.03)</b>	<b>,08 (.03)</b>	,25 (.08)
	300	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100,0%	<b>,98 (.01)</b>	<b>,08 (.03)</b>	<b>,07 (.02)</b>	,20 (.07)
	400	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100,0%	<b>,99 (.01)</b>	<b>,07 (.02)</b>	<b>,06 (.02)</b>	,17 (.06)
	500	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100,0%	<b>,99 (.01)</b>	<b>,06 (.02)</b>	<b>,05 (.02)</b>	,15 (.05)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del Modelo de Independencia; T1 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia. n.a. - No aplicable.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSE_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ). Soluciones estimadas mediante ML.

**Tabla 2.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 5)$				$\hat{\Sigma}_0 (n = 5)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
0,2	200	<b>3,07</b> ( <b>,692</b> )	,86 (,13)	,94 (,13)	,65 (,04)	<b>5,88</b> ( <b>,409</b> )	<b>1,25</b> ( <b>,17</b> )	<b>1,30</b> ( <b>,19</b> )	,80 (,06)
	300	<b>3,11</b> ( <b>,689</b> )	,87 (,13)	,96 (,13)	,65 (,04)	<b>5,37</b> ( <b>,443</b> )	<b>1,29</b> ( <b>,19</b> )	<b>1,35</b> ( <b>,22</b> )	,79 (,07)
	400	<b>3,07</b> ( <b>,694</b> )	,89 (,13)	,98 (,13)	,65 (,04)	<b>5,37</b> ( <b>,453</b> )	<b>1,32</b> ( <b>,21</b> )	<b>1,38</b> ( <b>,25</b> )	,79 (,07)
	500	<b>3,04</b> ( <b>,695</b> )	,91 (,13)	<b>1,00</b> ( <b>,14</b> )	,65 (,04)	<b>5,06</b> ( <b>,486</b> )	<b>1,35</b> ( <b>,21</b> )	<b>1,42</b> ( <b>,24</b> )	,79 (,07)
0,3	200	<b>3,07</b> ( <b>,691</b> )	,96 (,12)	<b>1,05</b> ( <b>,13</b> )	,69 (,04)	<b>5,04</b> ( <b>,495</b> )	<b>1,54</b> ( <b>,34</b> )	<b>1,63</b> ( <b>,38</b> )	,91 (,13)
	300	<b>3,13</b> ( <b>,683</b> )	<b>1,01</b> ( <b>,12</b> )	<b>1,10</b> ( <b>,14</b> )	,70 (,04)	<b>4,83</b> ( <b>,513</b> )	<b>1,77</b> ( <b>,44</b> )	<b>1,87</b> ( <b>,49</b> )	,97 (,16)
	400	<b>3,30</b> ( <b>,657</b> )	<b>1,03</b> ( <b>,06</b> )	<b>1,11</b> ( <b>,07</b> )	,69 (,02)	<b>4,88</b> ( <b>,514</b> )	<b>2,03</b> ( <b>,54</b> )	<b>2,15</b> ( <b>,59</b> )	<b>1,04</b> ( <b>,18</b> )
	500	<b>3,47</b> ( <b>,611</b> )	<b>1,05</b> ( <b>,06</b> )	<b>1,12</b> ( <b>,10</b> )	,69 (,02)	<b>4,82</b> ( <b>,516</b> )	<b>2,33</b> ( <b>,61</b> )	<b>2,47</b> ( <b>,67</b> )	<b>1,13</b> ( <b>,20</b> )
0,4	200	<b>1,67</b> ( <b>,868</b> )	,98 (,13)	<b>1,13</b> ( <b>,08</b> )	,71 (,03)	<b>5,06</b> ( <b>,500</b> )	<b>2,70</b> ( <b>,75</b> )	<b>2,86</b> ( <b>,83</b> )	<b>1,36</b> ( <b>,28</b> )
	300	n.a.	n.a.	n.a.	n.a.	<b>4,89</b> ( <b>,510</b> )	<b>3,71</b> ( <b>,93</b> )	<b>3,92</b> ( <b>1,03</b> )	<b>1,67</b> ( <b>,33</b> )
	400	n.a.	n.a.	n.a.	n.a.	<b>5,01</b> ( <b>,505</b> )	<b>4,67</b> ( <b>1,09</b> )	<b>4,94</b> ( <b>1,23</b> )	<b>1,96</b> ( <b>,37</b> )
	500	n.a.	n.a.	n.a.	n.a.	<b>4,92</b> ( <b>,508</b> )	<b>5,67</b> ( <b>1,23</b> )	<b>6,00</b> ( <b>1,40</b> )	<b>2,26</b> ( <b>,40</b> )

$\chi^2_0 (p-v)$  - Media (nivel crítico).

$ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ ;  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.

Soluciones estimadas mediante ML.

**Tabla 2.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 5)$						$\hat{\Sigma}_0 (n = 5)$					
		$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$	$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$
0,2	200	<b>,00</b> ( <b>,01</b> )	<b>,03</b> ( <b>,00</b> )	,73 (,12)	1,04 (5,97)	,47 (,26)	,61 (,46)	<b>,03</b> ( <b>,03</b> )	<b>,04</b> ( <b>,01</b> )	,75 (,12)	<b>,99</b> ( <b>,48</b> )	,49 (,25)	,88 (,17)
	300	<b>,00</b> ( <b>,01</b> )	<b>,02</b> ( <b>,00</b> )	,74 (,12)	1,3 (**)	,48 (,25)	,66 (,45)	<b>,02</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,77 (,11)	<b>,98</b> ( <b>,44</b> )	,54 (,24)	,90 (,13)
	400	<b>,00</b> ( <b>,01</b> )	<b>,02</b> ( <b>,00</b> )	,75 (,12)	1,4 (**)	,51 (,25)	,69 (,44)	<b>,02</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,78 (,12)	1,00 (,44)	,55 (,25)	,90 (,14)
	500	<b>,00</b> ( <b>,01</b> )	<b>,02</b> ( <b>,00</b> )	,76 (,11)	1,6 (**)	,52 (,23)	,77 (,40)	<b>,01</b> ( <b>,02</b> )	<b>,02</b> ( <b>,00</b> )	,80 (,11)	1,05 (,42)	,59 (,23)	,92 (,12)
0,3	200	<b>,00</b> ( <b>,01</b> )	<b>,03</b> ( <b>,00</b> )	,78 (,11)	1,8 (**)	,56 (,24)	,89 (,28)	<b>,02</b> ( <b>,03</b> )	<b>,04</b> ( <b>,01</b> )	,83 (,10)	1,06 (,35)	,65 (,21)	,94 (,10)
	300	<b>,00</b> ( <b>,01</b> )	<b>,02</b> ( <b>,00</b> )	,79 (,11)	1,6 (4,52)	,59 (,22)	,90 (,27)	<b>,02</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,86 (,08)	1,06 (,27)	,72 (,17)	<b>,96</b> ( <b>,07</b> )
	400	<b>,00</b> ( <b>,01</b> )	<b>,02</b> ( <b>,00</b> )	,79 (,06)	1,7 (,45)	,58 (,14)	<b>,99</b> ( <b>,02</b> )	<b>,01</b> ( <b>,02</b> )	<b>,02</b> ( <b>,00</b> )	,88 (,07)	1,05 (,22)	,76 (,15)	<b>,96</b> ( <b>,06</b> )
	500	<b>,00</b> ( <b>,00</b> )	<b>,02</b> ( <b>,00</b> )	,78 (,10)	1,4 (,51)	,56 (,20)	<b>1,00</b> ( <b>,00</b> )	<b>,01</b> ( <b>,02</b> )	<b>,02</b> ( <b>,00</b> )	,90 (,06)	1,04 (,18)	,80 (,13)	<b>,97</b> ( <b>,05</b> )
0,4	200	<b>,00</b> ( <b>,00</b> )	<b>,02</b> ( <b>,00</b> )	,89 (,06)	3,4 (2,41)	,79 (,14)	<b>1,00</b> ( <b>,00</b> )	<b>,02</b> ( <b>,03</b> )	<b>,03</b> ( <b>,01</b> )	,91 (,06)	1,03 (,16)	,82 (,13)	<b>,97</b> ( <b>,05</b> )
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,02</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,94 (,04)	1,02 (,09)	,88 (,08)	<b>,98</b> ( <b>,03</b> )
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01</b> ( <b>,02</b> )	<b>,02</b> ( <b>,00</b> )	,95 (,03)	1,02 (,07)	,91 (,06)	<b>,99</b> ( <b>,02</b> )
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01</b> ( <b>,02</b> )	<b>,02</b> ( <b>,00</b> )	,96 (,02)	1,01 (,05)	,93 (,05)	<b>,99</b> ( <b>,01</b> )

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

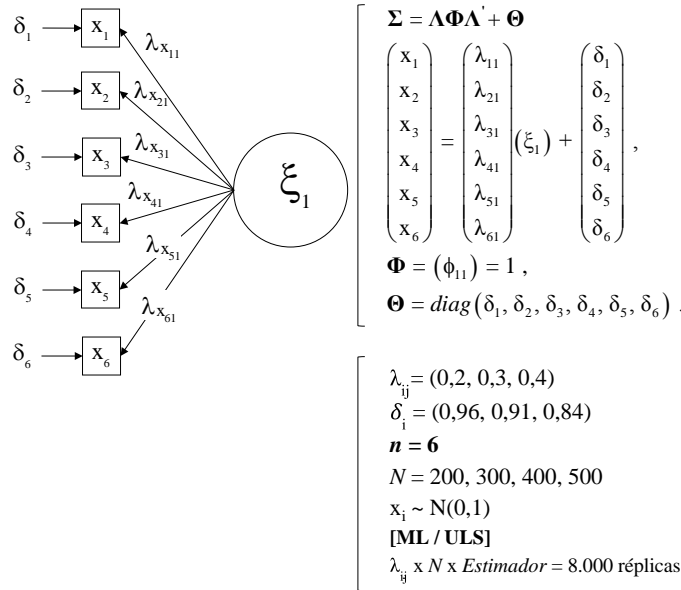
<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T.  $> 10$ .

n.a. - No aplicable.

Soluciones estimadas mediante ML.

Ficha 3. Modelos simulados y síntesis de resultados ( $n = 6$ )

**Cuadro 3.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 3.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%)

$\lambda_{ij}$	$N$	$ML (n = 6)$			$ULS (n = 6)$		
		IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$	IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$
0,2	200	31,0%	50,4%	18,6%	24,3%	55,2%	20,5%
	300	24,9%	44,3%	30,8%	17,8%	50,4%	31,8%
	400	19,6%	39,0%	41,4%	15,1%	42,4%	42,5%
	500	15,8%	32,8%	51,4%	11,7%	35,5%	52,8%
0,3	200	4,2%	11,7%	84,1%	1,7%	13,1%	85,2%
	300	1,1%	3,1%	95,8%	0,4%	3,2%	96,4%
	400	0,3%	0,7%	99,0%	0,0%	0,7%	99,3%
	500	0,1%	0,1%	99,8%	0,0%	0,1%	99,9%
0,4	200	0,0%	0,0%	100%	0,0%	0,0%	100%
	300	0,0%	0,0%	100%	0,0%	0,0%	100%
	400	0,0%	0,0%	100%	0,0%	0,0%	100%
	500	0,0%	0,0%	100%	0,0%	0,0%	100%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 3.2.** Ajuste teórico en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).  $\lambda_{ij} \times N$ , estimación ML (Media (D.T.))

$\lambda_{ij}$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (n = 6)$					$\hat{\Sigma}_0 (n = 6)$				
			T2	$C_j$	$RMSE_j$	$ARB_j$	$AMSE_j$	T1	$C_j$	$RMSE_j$	$ARB_j$	$AMSE_j$
0,2	200	69,0%	50,4%	,56 (.48)	,22 (.10)	,17 (.09)	1,08 (.51)	18,6%	,70 (.42)	,21 (.09)	,17 (.08)	1,06 (.46)
	300	75,1%	44,3%	,67 (.41)	<b>,17 (.09)</b>	,14 (.08)	,86 (.45)	30,8%	,77 (.35)	<b>,17 (.08)</b>	,14 (.07)	,84 (.39)
	400	80,4%	39,0%	,73 (.35)	<b>,15 (.08)</b>	,12 (.07)	,75 (.42)	41,4%	,82 (.29)	<b>,14 (.07)</b>	,12 (.06)	,72 (.33)
	500	84,2%	32,8%	,78 (.30)	<b>,13 (.07)</b>	,11 (.06)	,65 (.36)	51,4%	,84 (.26)	<b>,13 (.06)</b>	<b>,10 (.05)</b>	,64 (.32)
0,3	200	95,8%	11,7%	,83 (.26)	<b>,15 (.09)</b>	,13 (.08)	,51 (.29)	84,1%	<b>,92 (.08)</b>	<b>,13 (.05)</b>	<b>,10 (.04)</b>	,42 (.15)
	300	98,9%	3,1%	,90 (.06)	<b>,13 (.03)</b>	,11 (.03)	,43 (.10)	95,8%	<b>,94 (.09)</b>	<b>,10 (.04)</b>	<b>,09 (.04)</b>	,34 (.13)
	400	99,7%	0,7%	<b>,93 (.04)</b>	<b>,11 (.03)</b>	<b>,10 (.03)</b>	,38 (.09)	99,0%	<b>,96 (.03)</b>	<b>,09 (.03)</b>	<b>,07 (.02)</b>	,29 (.09)
	500	99,9%	0,1%	<b>,97 (.00)</b>	<b>,09 (.00)</b>	<b>,07 (.00)</b>	,29 (.00)	99,8%	<b>,97 (.02)</b>	<b>,08 (.02)</b>	<b>,06 (.02)</b>	,26 (.08)
0,4	200	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,97 (.02)</b>	<b>,09 (.03)</b>	<b>,08 (.02)</b>	,23 (.07)
	300	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,98 (.01)</b>	<b>,07 (.02)</b>	<b>,06 (.02)</b>	,19 (.06)
	400	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.01)</b>	<b>,06 (.02)</b>	<b>,05 (.02)</b>	,16 (.05)
	500	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.01)</b>	<b>,06 (.02)</b>	<b>,05 (.01)</b>	,14 (.04)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del Modelo de Independencia; T1 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia. n.a. - No aplicable.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSE_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

Soluciones estimadas mediante ML.



**Tabla 3.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 6)$				$\hat{\Sigma}_0 (n = 6)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
0,2	200	<b>6,64</b> ( <b>,667</b> )	,88 (.13)	,96 (.12)	,67 (.04)	<b>9,78</b> ( <b>,432</b> )	<b>1,23</b> ( <b>,15</b> )	<b>1,28</b> ( <b>,18</b> )	,80 (.06)
	300	<b>6,49</b> ( <b>,678</b> )	,91 (.13)	,99 (.12)	,67 (.04)	<b>9,70</b> ( <b>,433</b> )	<b>1,27</b> ( <b>,17</b> )	<b>1,32</b> ( <b>,20</b> )	,80 (.06)
	400	<b>6,22</b> ( <b>,703</b> )	,92 (.13)	<b>1,01</b> ( <b>,13</b> )	,67 (.04)	<b>9,92</b> ( <b>,417</b> )	<b>1,30</b> ( <b>,18</b> )	<b>1,35</b> ( <b>,22</b> )	,80 (.07)
	500	<b>6,15</b> ( <b>,710</b> )	,95 (.10)	<b>1,05</b> ( <b>,12</b> )	,68 (.03)	<b>9,34</b> ( <b>,470</b> )	<b>1,35</b> ( <b>,22</b> )	<b>1,41</b> ( <b>,25</b> )	,81 (.08)
0,3	200	<b>6,07</b> ( <b>,715</b> )	,98 (.09)	<b>1,09</b> ( <b>,11</b> )	,72 (.03)	<b>8,89</b> ( <b>,501</b> )	<b>1,58</b> ( <b>,36</b> )	<b>1,67</b> ( <b>,40</b> )	,95 (.14)
	300	<b>5,92</b> ( <b>,732</b> )	<b>1,01</b> ( <b>,06</b> )	<b>1,13</b> ( <b>,10</b> )	,72 (.02)	<b>8,87</b> ( <b>,502</b> )	<b>1,89</b> ( <b>,47</b> )	<b>2,00</b> ( <b>,51</b> )	<b>1,04</b> ( <b>,17</b> )
	400	<b>4,99</b> ( <b>,814</b> )	<b>1,04</b> ( <b>,04</b> )	<b>1,18</b> ( <b>,08</b> )	,72 (.02)	<b>9,01</b> ( <b>,496</b> )	<b>2,21</b> ( <b>,54</b> )	<b>2,33</b> ( <b>,59</b> )	<b>1,14</b> ( <b>,20</b> )
	500	,89 (.000)	<b>1,07</b> ( <b>,00</b> )	<b>1,41</b> ( <b>,00</b> )	,76 (.00)	<b>8,94</b> ( <b>,506</b> )	<b>2,57</b> ( <b>,64</b> )	<b>2,73</b> ( <b>,71</b> )	<b>1,26</b> ( <b>,22</b> )
0,4	200	n.a.	n.a.	n.a.	n.a.	<b>8,92</b> ( <b>,503</b> )	<b>2,98</b> ( <b>,79</b> )	<b>3,16</b> ( <b>,88</b> )	<b>1,52</b> ( <b>,32</b> )
	300	n.a.	n.a.	n.a.	n.a.	<b>9,01</b> ( <b>,495</b> )	<b>4,11</b> ( <b>,98</b> )	<b>4,35</b> ( <b>,10</b> )	<b>1,90</b> ( <b>,37</b> )
	400	n.a.	n.a.	n.a.	n.a.	<b>9,13</b> ( <b>,488</b> )	<b>5,22</b> ( <b>,13</b> )	<b>5,52</b> ( <b>,29</b> )	<b>2,26</b> ( <b>,41</b> )
	500	n.a.	n.a.	n.a.	n.a.	<b>9,05</b> ( <b>,499</b> )	<b>6,37</b> ( <b>,133</b> )	<b>6,76</b> ( <b>,54</b> )	<b>2,63</b> ( <b>,46</b> )

$\chi^2_0 (p-v)$  - Media (nivel crítico).

$ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ ;  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.

Soluciones estimadas mediante ML.

**Tabla 3.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 6)$						$\hat{\Sigma}_0 (n = 6)$					
		$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$	$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$
0,2	200	<b>,01</b> ( <b>,01</b> )	<b>,04</b> ( <b>,00</b> )	,62 (.13)	<b>,98</b> (**)	,36 (.22)	,62 (.45)	<b>,02</b> ( <b>,02</b> )	<b>,04</b> ( <b>,00</b> )	,68 (.12)	,94 (.42)	,47 (.20)	,88 (.16)
	300	<b>,00</b> ( <b>,01</b> )	<b>,03</b> ( <b>,00</b> )	,64 (.12)	1,23 (**)	,41 (.20)	,69 (.43)	<b>,02</b> ( <b>,02</b> )	<b>,04</b> ( <b>,00</b> )	,69 (.11)	<b>,97</b> ( <b>,39</b> )	,49 (.19)	,89 (.15)
	400	<b>,00</b> ( <b>,01</b> )	<b>,03</b> ( <b>,00</b> )	,66 (.11)	1,39 (**)	,44 (.19)	,73 (.42)	<b>,02</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,70 (.11)	<b>,93</b> ( <b>,37</b> )	,49 (.19)	,89 (.14)
	500	<b>,00</b> ( <b>,01</b> )	<b>,02</b> ( <b>,00</b> )	,68 (.12)	1,70 (**)	,47 (.20)	,84 (.33)	<b>,01</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,72 (.11)	1,01 (.36)	,54 (.19)	,91 (.13)
0,3	200	<b>,00</b> ( <b>,01</b> )	<b>,03</b> ( <b>,00</b> )	,71 (.11)	1,8 (8,99)	,51 (.19)	,91 (.25)	<b>,02</b> ( <b>,02</b> )	<b>,04</b> ( <b>,01</b> )	,78 (.10)	1,03 (.30)	,63 (.17)	,94 (.10)
	300	<b>,00</b> ( <b>,01</b> )	<b>,03</b> ( <b>,00</b> )	,73 (.11)	1,9 (0,92)	,54 (.20)	<b>,97</b> ( <b>,12</b> )	<b>,01</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,82 (.08)	1,03 (.23)	,70 (.15)	<b>,96</b> ( <b>,07</b> )
	400	<b>,00</b> ( <b>,00</b> )	<b>,02</b> ( <b>,00</b> )	,77 (.07)	1,9 (0,44)	,62 (.13)	<b>1,00</b> ( <b>,00</b> )	<b>,01</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,85 (.07)	1,02 (.17)	,75 (.12)	<b>,97</b> ( <b>,06</b> )
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,88 (.06)	1,02 (.14)	,79 (.11)	<b>,97</b> ( <b>,05</b> )
0,4	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,02</b> ( <b>,02</b> )	<b>,04</b> ( <b>,00</b> )	,89 (.05)	1,01 (.11)	,82 (.10)	<b>,98</b> ( <b>,04</b> )
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,93 (.03)	1,01 (.07)	,88 (.06)	<b>,98</b> ( <b>,02</b> )
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01</b> ( <b>,02</b> )	<b>,03</b> ( <b>,00</b> )	,94 (.02)	1,00 (.05)	,91 (.05)	<b>,99</b> ( <b>,02</b> )
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01</b> ( <b>,02</b> )	<b>,02</b> ( <b>,00</b> )	,95 (.02)	1,01 (.04)	,92 (.04)	<b>,99</b> ( <b>,01</b> )

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

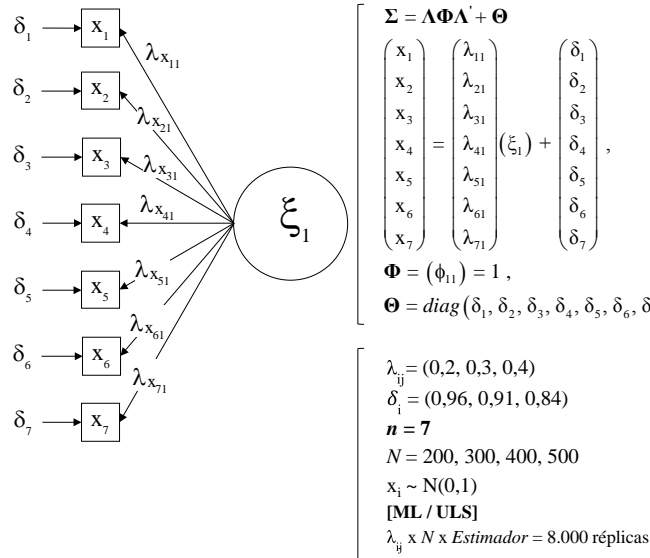
<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T.  $> 10$ .

n.a. - No aplicable.

Soluciones estimadas mediante ML.

Ficha 4. Modelos simulados y síntesis de resultados ( $n = 7$ )

**Cuadro 4.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 4.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%)

$\lambda_{ij}$	$N$	$ML (n = 7)$			$ULS (n = 7)$		
		IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$	IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$
0,2	200	26,9%	48,5%	24,6%	17,9%	54,6%	27,5%
	300	21,6%	42,5%	35,9%	15,3%	47,1%	37,6%
	400	12,9%	36,5%	50,6%	9,3%	38,7%	52,0%
	500	9,7%	28,9%	61,4%	7,2%	29,8%	63,0%
0,3	200	1,7%	6,5%	91,8%	0,6%	6,7%	92,7%
	300	0,1%	1,2%	98,7%	0,0%	1,2%	98,8%
	400	0,0%	0,2%	99,8%	0,0%	0,2%	99,8%
	500	0,0%	0,0%	100%	0,0%	0,0%	100%
0,4	200	0,0%	0,0%	100%	0,0%	0,0%	100%
	300	0,0%	0,0%	100%	0,0%	0,0%	100%
	400	0,0%	0,0%	100%	0,0%	0,0%	100%
	500	0,0%	0,0%	100%	0,0%	0,0%	100%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 4.2.** Ajuste teórico en función del resultado del test  $\chi^2_{\text{Null}} (\alpha = 0,05)$ .  $\lambda_{ij} \times N$ , estimación ML (Media (D.T.))

$\lambda_{ij}$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (n = 7)$					$\hat{\Sigma}_0 (n = 7)$				
			T2	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	T1	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
0,2	200	73,1%	48,5%	,60 (.45)	,20 (.09)	,16 (.08)	,99 (.46)	24,6%	,75 (.36)	<b>,19 (.08)</b>	,15 (.07)	,94 (.39)
	300	78,4%	42,5%	,71 (.36)	<b>,16 (.08)</b>	,13 (.07)	,79 (.39)	35,9%	,82 (.24)	<b>,15 (.06)</b>	,12 (.05)	,75 (.29)
	400	87,1%	36,5%	,73 (.35)	<b>,14 (.07)</b>	,12 (.07)	,71 (.37)	50,6%	,84 (.26)	<b>,13 (.06)</b>	,11 (.05)	,65 (.29)
	500	90,3%	28,9%	,77 (.32)	<b>,13 (.07)</b>	,11 (.06)	,64 (.35)	61,4%	,87 (.18)	<b>,11 (.05)</b>	<b>,09 (.04)</b>	,56 (.25)
0,3	200	98,3%	6,5%	,86 (.22)	<b>,14 (.07)</b>	,12 (.06)	,48 (.23)	91,8%	<b>,93 (.12)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,39 (.15)
	300	99,9%	1,2%	,88 (.07)	<b>,14 (.04)</b>	,12 (.04)	,48 (.12)	98,7%	<b>,95 (.03)</b>	<b>,09 (.03)</b>	<b>,08 (.02)</b>	,31 (.09)
	400	100,0%	0,2%	,89 (.05)	<b>,14 (.03)</b>	,13 (.03)	,46 (.09)	99,8%	<b>,97 (.02)</b>	<b>,08 (.02)</b>	<b>,07 (.02)</b>	,27 (.07)
	500	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,97 (.02)</b>	<b>,07 (.02)</b>	<b>,06 (.02)</b>	,23 (.07)
0,4	200	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,98 (.02)</b>	<b>,09 (.02)</b>	<b>,07 (.02)</b>	,22 (.06)
	300	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.01)</b>	<b>,07 (.02)</b>	<b>,06 (.02)</b>	,18 (.05)
	400	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.01)</b>	<b>,06 (.02)</b>	<b>,05 (.01)</b>	,15 (.04)
	500	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.01)</b>	<b>,05 (.02)</b>	<b>,04 (.01)</b>	,13 (.04)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del Modelo de Independencia; T1 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia. n.a. - No aplicable.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

Soluciones estimadas mediante ML.

**Tabla 4.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 7)$				$\hat{\Sigma}_0 (n = 7)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
0,2	200	<b>10,8 (,681)</b>	,90 (,11)	,99 (,11)	,69 (,04)	<b>15,8 (,400)</b>	<b>1,22 (,14)</b>	<b>1,26 (,17)</b>	,82 (,06)
	300	<b>10,5 (,701)</b>	,93 (,10)	<b>1,03 (,11)</b>	,69 (,04)	<b>15,1 (,429)</b>	<b>1,27 (,16)</b>	<b>1,32 (,19)</b>	,82 (,06)
	400	<b>10,4 (,700)</b>	,94 (,11)	<b>1,03 (,11)</b>	,69 (,03)	<b>14,9 (,433)</b>	<b>1,30 (,20)</b>	<b>1,35 (,22)</b>	,82 (,07)
	500	<b>10,1 (,723)</b>	,95 (,09)	<b>1,06 (,11)</b>	,69 (,03)	<b>14,6 (,455)</b>	<b>1,35 (,23)</b>	<b>1,41 (,26)</b>	,83 (,09)
0,3	200	<b>10,1 (,728)</b>	<b>1,02 (,08)</b>	<b>1,14 (,12)</b>	,74 (,03)	<b>14,3 (,484)</b>	<b>1,65 (,37)</b>	<b>1,74 (,40)</b>	<b>1,00 (,16)</b>
	300	<b>11,1 (,665)</b>	<b>1,04 (,02)</b>	<b>1,14 (,09)</b>	,74 (,02)	<b>14,1 (,493)</b>	<b>2,00 (,47)</b>	<b>2,11 (,53)</b>	<b>1,12 (,19)</b>
	400	<b>8,99 (,831)</b>	<b>1,07 (,02)</b>	<b>1,21 (,01)</b>	,75 (,00)	<b>14,0 (,491)</b>	<b>2,37 (,57)</b>	<b>2,49 (,61)</b>	<b>1,24 (,22)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>14,1 (,491)</b>	<b>2,75 (,65)</b>	<b>2,91 (,72)</b>	<b>1,37 (,24)</b>
0,4	200	n.a.	n.a.	n.a.	n.a.	<b>14,4 (,482)</b>	<b>3,27 (,80)</b>	<b>3,45 (,89)</b>	<b>1,70 (,34)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>14,3 (,485)</b>	<b>4,49 (1,01)</b>	<b>4,75 (1,15)</b>	<b>2,14 (,40)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>14,1 (,485)</b>	<b>5,70 (1,18)</b>	<b>6,02 (1,32)</b>	<b>2,55 (,45)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>14,2 (,486)</b>	<b>6,92 (1,36)</b>	<b>7,33 (1,59)</b>	<b>2,97 (,50)</b>

$\chi^2_0 (p-v)$  - Media (nivel crítico).

$ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ ;  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.

Soluciones estimadas mediante ML.

**Tabla 4.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

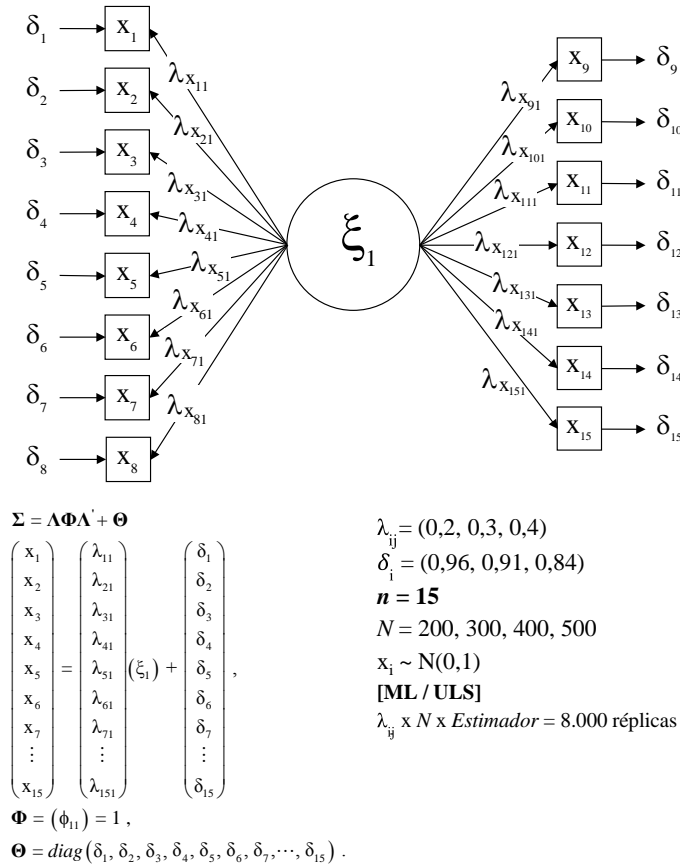
$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 7)$						$\hat{\Sigma}_0 (n = 7)$					
		$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$	$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$
0,2	200	<b>,00 (,01)</b>	<b>,04 (,00)</b>	,55 (,12)	1,1 (**)	,32 (,18)	,66 (,44)	<b>,02 (,02)</b>	<b>,05 (,00)</b>	,61 (,12)	,88 (,41)	,41 (,18)	,85 (,18)
	300	<b>,00 (,01)</b>	<b>,03 (,00)</b>	,58 (,11)	1,6 (**)	,37 (,17)	,79 (,38)	<b>,02 (,02)</b>	<b>,04 (,00)</b>	,64 (,11)	,94 (,38)	,46 (,18)	,88 (,15)
	400	<b>,00 (,01)</b>	<b>,03 (,00)</b>	,59 (,11)	1,4 (2,98)	,38 (,17)	,77 (,39)	<b>,01 (,02)</b>	<b>,03 (,00)</b>	,65 (,11)	<b>,97 (,34)</b>	,47 (,17)	,90 (,14)
	500	<b>,00 (,01)</b>	<b>,03 (,00)</b>	,61 (,11)	1,6 (**)	,42 (,18)	,83 (,35)	<b>,01 (,01)</b>	<b>,03 (,00)</b>	,67 (,11)	<b>,98 (,35)</b>	,50 (,17)	,91 (,13)
0,3	200	<b>,00 (,01)</b>	<b>,04 (,00)</b>	,64 (,10)	1,8 (3,24)	,47 (,16)	<b>,96 (,13)</b>	<b>,02 (,02)</b>	<b>,04 (,00)</b>	,74 (,10)	1,02 (,27)	,61 (,15)	,94 (,10)
	300	<b>,00 (,01)</b>	<b>,03 (,00)</b>	,63 (,09)	1,5 (,44)	,45 (,14)	<b>,97 (,07)</b>	<b>,01 (,02)</b>	<b>,04 (,00)</b>	,80 (,08)	1,02 (,19)	,69 (,13)	<b>,96 (,07)</b>
	400	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,71 (,01)	1,8 (,19)	,56 (,02)	<b>1,00 (,00)</b>	<b>,01 (,01)</b>	<b>,03 (,00)</b>	,83 (,06)	1,01 (,14)	,75 (,10)	<b>,97 (,05)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,03 (,00)</b>	,86 (,06)	1,01 (,11)	,79 (,09)	<b>,97 (,04)</b>
0,4	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,02 (,02)</b>	<b>,04 (,00)</b>	,88 (,05)	1,01 (,09)	,82 (,08)	<b>,98 (,03)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,00)</b>	,92 (,03)	1,00 (,06)	,88 (,06)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,00)</b>	,94 (,02)	1,00 (,04)	,91 (,04)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,03 (,00)</b>	,95 (,02)	1,00 (,03)	,92 (,03)	<b>,99 (,01)</b>

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T.  $> 10$ .

n.a. - No aplicable.

Soluciones estimadas mediante ML.

Ficha 5. Modelos simulados y síntesis de resultados ( $n = 15$ )**Cuadro 5.1.** Path diagram, notación matricial y condiciones simuladas**Tabla 5.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%)

$\lambda_{ij}$	$N$	$ML (n = 15)$			$ULS (n = 15)$		
		IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$	IM	$\hat{\Sigma}_{\text{Null}}$	$\hat{\Sigma}_0$
0,2	200	3,1%	34,5%	62,4%	1,2%	35,7%	63,1%
	300	0,8%	14,0%	85,2%	0,5%	14,3%	85,2%
	400	0,0%	5,4%	94,6%	0,0%	5,4%	94,6%
	500	0,1%	0,9%	99,0%	0,0%	0,9%	99,1%
0,3	200	0,0%	0,0%	100%	0,0%	0,0%	100%
	300	0,0%	0,0%	100%	0,0%	0,0%	100%
	400	0,0%	0,0%	100%	0,0%	0,0%	100%
	500	0,0%	0,0%	100%	0,0%	0,0%	100%
0,4	200	0,0%	0,0%	100%	0,0%	0,0%	100%
	300	0,0%	0,0%	100%	0,0%	0,0%	100%
	400	0,0%	0,0%	100%	0,0%	0,0%	100%
	500	0,0%	0,0%	100%	0,0%	0,0%	100%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 5.2.** Ajuste teórico en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).  $\lambda_{ij} \times N$ , estimación ML (Media (D.T.))

$\lambda_{ij}$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (n = 15)$					$\hat{\Sigma}_0 (n = 15)$				
			T2	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	T1	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
0,2	200	96,9%	34,5%	,66 (.43)	<b>,16 (.08)</b>	,13 (.07)	,78 (.39)	62,4%	,77 (.36)	<b>,14 (.07)</b>	,11 (.07)	,69 (.34)
	300	99,2%	14,0%	,78 (.34)	<b>,12 (.06)</b>	<b>,10 (.06)</b>	,59 (.30)	85,2%	,85 (.27)	<b>,11 (.05)</b>	<b>,09 (.05)</b>	,53 (.26)
	400	100,0%	5,4%	,88 (.08)	<b>,09 (.03)</b>	<b>,07 (.02)</b>	,46 (.14)	94,6%	,90 (.21)	<b>,09 (.04)</b>	<b>,07 (.04)</b>	,44 (.20)
	500	99,9%	0,9%	,86 (.08)	<b>,10 (.03)</b>	<b>,08 (.02)</b>	,49 (.14)	99,0%	<b>,93 (.13)</b>	<b>,08 (.03)</b>	<b>,06 (.03)</b>	,38 (.14)
0,3	200	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,96 (.02)</b>	<b>,09 (.02)</b>	<b>,07 (.01)</b>	,29 (.06)
	300	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,97 (.01)</b>	<b>,07 (.01)</b>	<b>,06 (.01)</b>	,24 (.04)
	400	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,98 (.01)</b>	<b>,06 (.01)</b>	<b>,05 (.01)</b>	,20 (.04)
	500	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,98 (.01)</b>	<b>,05 (.01)</b>	<b>,04 (.01)</b>	,18 (.03)
0,4	200	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.01)</b>	<b>,07 (.01)</b>	<b>,06 (.01)</b>	,18 (.03)
	300	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.00)</b>	<b>,06 (.01)</b>	<b>,05 (.01)</b>	,15 (.03)
	400	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.00)</b>	<b>,05 (.01)</b>	<b>,04 (.01)</b>	,13 (.02)
	500	100%	0,0%	n.a.	n.a.	n.a.	n.a.	100%	<b>,99 (.00)</b>	<b>,04 (.01)</b>	<b>,04 (.01)</b>	,11 (.02)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del Modelo de Independencia; T1 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia. n.a. - No aplicable.Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

Soluciones estimadas mediante ML.

**Tabla 5.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 15)$				$\hat{\Sigma}_0 (n = 15)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
0,2	200	<b>81,4 (,688)</b>	,97 (,06)	<b>1,05 (,07)</b>	,79 (,03)	<b>95,5 (,381)</b>	<b>1,17 (,10)</b>	<b>1,20 (,12)</b>	,88 (,06)
	300	<b>79,7 (,730)</b>	,99 (,05)	<b>1,08 (,06)</b>	,79 (,02)	<b>93,8 (,419)</b>	<b>1,24 (,13)</b>	<b>1,28 (,15)</b>	,90 (,07)
	400	<b>75,9 (,807)</b>	<b>1,01 (,04)</b>	<b>1,13 (,07)</b>	,80 (,02)	<b>91,2 (,472)</b>	<b>1,33 (,16)</b>	<b>1,38 (,17)</b>	,94 (,08)
	500	<b>74,1 (,809)</b>	<b>1,03 (,03)</b>	<b>1,16 (,08)</b>	,80 (,02)	<b>91,0 (,479)</b>	<b>1,43 (,18)</b>	<b>1,48 (,19)</b>	,98 (,09)
0,3	200	n.a.	n.a.	n.a.	n.a.	<b>92,3 (,456)</b>	<b>1,96 (,36)</b>	<b>2,04 (,38)</b>	<b>1,33 (,20)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>92,8 (,445)</b>	<b>2,51 (,44)</b>	<b>2,61 (,48)</b>	<b>1,58 (,23)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>91,1 (,476)</b>	<b>3,08 (,51)</b>	<b>3,21 (,56)</b>	<b>1,85 (,26)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>91,4 (,472)</b>	<b>3,63 (,56)</b>	<b>3,77 (,63)</b>	<b>2,09 (,28)</b>
0,4	200	n.a.	n.a.	n.a.	n.a.	<b>92,5 (,451)</b>	<b>4,31 (,84)</b>	<b>4,48 (,92)</b>	<b>2,63 (,46)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>92,9 (,442)</b>	<b>6,03 (1,03)</b>	<b>6,26 (1,16)</b>	<b>3,46 (,55)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>91,2 (,473)</b>	<b>7,82 (1,20)</b>	<b>8,14 (1,37)</b>	<b>4,30 (,62)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>91,5 (,470)</b>	<b>9,55 (1,35)</b>	<b>9,92 (1,58)</b>	<b>5,09 (,67)</b>

$\chi^2_0 (p-v)$  - Media (nivel crítico).

$ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ ;  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.

Soluciones estimadas mediante ML.

**Tabla 5.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$\lambda_{ij}$  x  $N$ , estimación ML (Media (D.T.) sobre soluciones válidas)

$\lambda_{ij}$	$N$	$\hat{\Sigma}_{Null} (n = 15)$						$\hat{\Sigma}_0 (n = 15)$					
		$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$	$RMSEA$	$SRMR$	$NFI$	$NNFI^{(a)}$	$RFI$	$CFI$
0,2	200	<b>,00 (,00)</b>	<b>,06 (,00)</b>	,30 (,07)	1,4 (**)	,18 (,09)	,80 (,35)	<b>,01 (,01)</b>	<b>,06 (,00)</b>	,37 (,08)	,88 (,33)	,26 (,10)	,83 (,19)
	300	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,33 (,06)	1,7 (6,92)	,22 (,08)	,94 (,20)	<b>,01 (,01)</b>	<b>,05 (,00)</b>	,42 (,08)	,93 (,30)	,32 (,10)	,88 (,15)
	400	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,38 (,06)	1,8 (1,58)	,27 (,08)	<b>,98 (,13)</b>	<b>,01 (,01)</b>	<b>,04 (,00)</b>	,48 (,08)	<b>,99 (,26)</b>	,39 (,10)	,92 (,11)
	500	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,40 (,08)	2,2 (1,09)	,30 (,10)	<b>1,00 (,00)</b>	<b>,01 (,01)</b>	<b>,04 (,00)</b>	,52 (,08)	1,00 (,22)	,44 (,10)	,94 (,09)
0,3	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,06 (,00)</b>	,65 (,07)	<b>,99 (,12)</b>	,59 (,09)	<b>,96 (,06)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,05 (,00)</b>	,74 (,05)	<b>,99 (,07)</b>	,69 (,07)	<b>,97 (,03)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,00)</b>	,79 (,04)	1,00 (,05)	,76 (,05)	<b>,98 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,00)</b>	,82 (,03)	1,00 (,04)	,80 (,04)	<b>,99 (,02)</b>
0,4	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,05 (,00)</b>	,85 (,03)	1,00 (,03)	,82 (,04)	<b>,99 (,02)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,00)</b>	,89 (,02)	1,00 (,02)	,88 (,03)	<b>,99 (,01)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,00)</b>	,92 (,01)	1,00 (,02)	,91 (,02)	<b>,99 (,00)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,03 (,00)</b>	,94 (,01)	1,00 (,01)	,93 (,02)	<b>1,00 (,00)</b>


Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T.  $> 10$ .

n.a. - No aplicable.

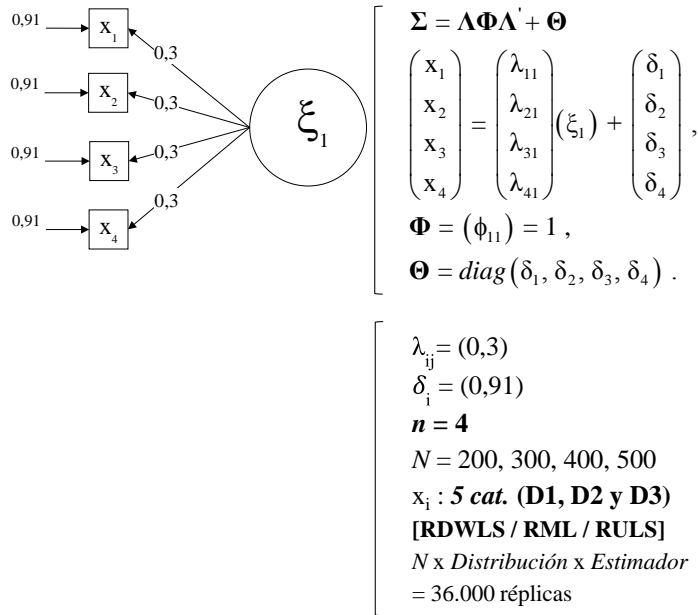
Soluciones estimadas mediante ML.

## C. Datos ordinales (5 categorías)



Ficha 6. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3$ ,  $n = 4$ )

**Cuadro 6.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 6.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución x N x Estimador.

Distribución	N	IM ( $\lambda_{ij} = 0,3; n = 4$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,3; n = 4$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,3; n = 4$ )		
		RDWLS	RML	RULS	RDWLS	RML	RULS	RDWLS	RML	RULS
D1	200	19,7%	23,8%	19,6%	21,9%	20,3%	21,8%	58,4%	55,9%	58,6%
	300	10,8%	13,2%	11,1%	13,4%	12,8%	13,1%	75,8%	74,0%	75,8%
	400	5,9%	7,2%	6,1%	6,3%	6,2%	6,3%	87,8%	86,6%	87,6%
	500	2,2%	3,9%	2,5%	4,5%	4,4%	4,5%	93,3%	91,7%	93,0%
D2	200	40,3%	47,4%	41,3%	16,5%	14,5%	16,6%	43,2%	38,1%	42,1%
	300	33,8%	38,7%	33,9%	9,1%	8,5%	9,3%	57,1%	52,8%	56,8%
	400	22,7%	28,5%	23,4%	4,2%	3,4%	4,0%	73,1%	68,1%	72,6%
	500	17,1%	21,4%	17,6%	2,7%	2,4%	2,8%	80,2%	76,2%	79,6%
D3	200	19,1%	23,2%	19,4%	23,4%	21,9%	23,3%	57,5%	54,9%	57,3%
	300	10,5%	13,2%	10,7%	13,7%	13,1%	13,6%	75,8%	73,7%	75,7%
	400	5,2%	7,0%	5,4%	6,9%	6,3%	6,7%	87,9%	86,7%	87,9%
	500	2,3%	3,0%	2,5%	4,0%	4,0%	4,0%	93,7%	93,0%	93,5%

IM- Soluciones impropias (no convergentes/casos Heywood).

D1, D2 y D3: Caso 1, 4 y 6 (Muthén y Kaplan, 1992).

**Tabla 6.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null} (\alpha = 0,05)$ . Distribución  $x \times N \times$  Estimador (Media (D.T.))

D1	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	82,2%	21,9%	,79 (.32)	<b>,18 (.11)</b>	,15 (.10)	,60 (.38)	58,4%	,90 (.15)	<b>,16 (.07)</b>	,13 (.06)	,54 (.24)
	300	89,0%	13,4%	,83 (.22)	<b>,17 (.09)</b>	,15 (.08)	,57 (.31)	75,8%	,91 (.13)	<b>,14 (.07)</b>	,12 (.06)	,47 (.22)
	400	95,0%	6,3%	,89 (.08)	<b>,13 (.05)</b>	,11 (.05)	,45 (.18)	87,8%	<b>,93 (.09)</b>	<b>,12 (.06)</b>	<b>,10 (.05)</b>	,41 (.20)
	500	97,2%	4,5%	,91 (.06)	<b>,13 (.04)</b>	,11 (.04)	,42 (.12)	93,3%	<b>,93 (.13)</b>	<b>,11 (.06)</b>	<b>,10 (.05)</b>	,38 (.21)
RML	200	76,2%	20,3%	,79 (.31)	<b>,18 (.11)</b>	,16 (.10)	,61 (.38)	55,9%	,90 (.15)	<b>,16 (.07)</b>	,13 (.06)	,55 (.24)
	300	86,8%	12,8%	,84 (.18)	<b>,17 (.09)</b>	,15 (.08)	,56 (.29)	74,0%	,91 (.11)	<b>,14 (.07)</b>	,12 (.05)	,47 (.22)
	400	92,8%	6,2%	,89 (.10)	<b>,14 (.06)</b>	,12 (.06)	,46 (.20)	86,6%	<b>,93 (.09)</b>	<b>,13 (.06)</b>	<b>,10 (.05)</b>	,42 (.20)
	500	96,1%	4,4%	,90 (.07)	<b>,13 (.04)</b>	,11 (.04)	,44 (.14)	91,7%	<b>,94 (.08)</b>	<b>,11 (.05)</b>	<b>,10 (.05)</b>	,38 (.18)
RULS	200	80,4%	21,8%	,80 (.30)	<b>,18 (.11)</b>	,15 (.10)	,60 (.38)	58,6%	,90 (.15)	<b>,16 (.07)</b>	,13 (.06)	,55 (.25)
	300	88,9%	13,1%	,83 (.22)	<b>,17 (.09)</b>	,15 (.08)	,57 (.30)	75,8%	,91 (.11)	<b>,14 (.07)</b>	,12 (.05)	,47 (.22)
	400	93,9%	6,3%	,89 (.08)	<b>,13 (.05)</b>	,11 (.05)	,44 (.17)	87,6%	<b>,93 (.09)</b>	<b>,12 (.06)</b>	<b>,10 (.05)</b>	,41 (.20)
	500	97,5%	4,5%	,91 (.07)	<b>,13 (.04)</b>	,11 (.04)	,43 (.12)	93,0%	<b>,93 (.13)</b>	<b>,11 (.06)</b>	<b>,10 (.05)</b>	,38 (.20)
D2	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	59,7%	16,5%	,59 (.45)	,28 (.14)	,23 (.12)	,94 (.47)	43,2%	,80 (.32)	,24 (.11)	,19 (.10)	,79 (.38)
	300	66,2%	9,1%	,74 (.35)	,22 (.12)	,18 (.11)	,72 (.41)	57,1%	,84 (.27)	,20 (.10)	,16 (.09)	,66 (.34)
	400	77,3%	4,2%	,81 (.23)	,18 (.09)	,15 (.08)	,61 (.31)	73,1%	,85 (.27)	<b>,18 (.10)</b>	,15 (.09)	,61 (.33)
	500	82,9%	2,7%	,72 (.44)	,21 (.13)	,18 (.12)	,69 (.42)	80,2%	,88 (.17)	<b>,16 (.08)</b>	,13 (.07)	,53 (.27)
RML	200	52,6%	14,5%	,62 (.40)	,27 (.13)	,23 (.11)	,91 (.42)	38,1%	,80 (.31)	,24 (.11)	,19 (.10)	,79 (.38)
	300	61,3%	8,5%	,73 (.33)	,22 (.12)	,19 (.10)	,74 (.39)	52,8%	,83 (.28)	,20 (.11)	,17 (.09)	,67 (.35)
	400	71,5%	3,4%	,82 (.24)	<b>,17 (.08)</b>	,14 (.07)	,56 (.27)	68,1%	,85 (.24)	<b>,18 (.09)</b>	,15 (.08)	,61 (.31)
	500	78,6%	2,4%	,78 (.34)	<b>,19 (.11)</b>	,16 (.10)	,62 (.35)	76,2%	,89 (.16)	<b>,16 (.08)</b>	,13 (.06)	,54 (.26)
RULS	200	58,7%	16,6%	,58 (.45)	,29 (.14)	,24 (.12)	,95 (.47)	42,1%	,80 (.32)	,24 (.11)	,19 (.10)	,79 (.38)
	300	66,1%	9,3%	,73 (.35)	,22 (.12)	,19 (.11)	,73 (.41)	56,8%	,84 (.27)	,20 (.10)	,16 (.09)	,66 (.34)
	400	76,6%	4,0%	,81 (.23)	<b>,18 (.09)</b>	,15 (.08)	,61 (.31)	72,6%	,85 (.26)	<b>,18 (.10)</b>	,15 (.08)	,61 (.32)
	500	82,4%	2,8%	,67 (.49)	,22 (.14)	,19 (.13)	,73 (.47)	79,6%	,88 (.17)	<b>,16 (.08)</b>	,13 (.07)	,53 (.26)
D3	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	80,9%	23,4%	,81 (.30)	<b>,18 (.10)</b>	,15 (.09)	,59 (.35)	57,5%	,90 (.14)	,16 (.07)	,13 (.06)	,55 (.25)
	300	89,5%	13,7%	,84 (.21)	<b>,16 (.09)</b>	,14 (.08)	,54 (.29)	75,8%	<b>,92 (.09)</b>	,14 (.06)	,11 (.05)	,46 (.21)
	400	94,8%	6,9%	,85 (.19)	<b>,16 (.10)</b>	,14 (.09)	,54 (.34)	87,9%	<b>,93 (.06)</b>	,12 (.05)	<b>,10 (.04)</b>	,41 (.18)
	500	97,7%	4,0%	,91 (.06)	<b>,13 (.04)</b>	,11 (.04)	,42 (.13)	93,7%	<b>,94 (.07)</b>	,11 (.05)	<b>,09 (.04)</b>	,36 (.17)
RML	200	76,8%	21,9%	,82 (.26)	<b>,17 (.09)</b>	,15 (.09)	,58 (.31)	54,9%	,90 (.14)	,17 (.07)	,14 (.06)	,56 (.25)
	300	86,8%	13,1%	,86 (.16)	<b>,16 (.07)</b>	,14 (.07)	,52 (.24)	73,7%	<b>,92 (.09)</b>	,14 (.06)	,12 (.05)	,47 (.21)
	400	93,0%	6,3%	,88 (.09)	<b>,15 (.06)</b>	,13 (.06)	,49 (.21)	86,7%	<b>,93 (.06)</b>	,12 (.06)	<b>,10 (.05)</b>	,42 (.19)
	500	97,0%	4,0%	,91 (.06)	<b>,13 (.04)</b>	,11 (.04)	,43 (.14)	93,0%	<b>,94 (.06)</b>	,11 (.05)	<b>,09 (.04)</b>	,37 (.17)
RULS	200	80,6%	23,3%	,81 (.28)	<b>,18 (.10)</b>	,15 (.09)	,59 (.33)	57,3%	,90 (.14)	,17 (.07)	,13 (.06)	,55 (.25)
	300	89,3%	13,6%	,85 (.16)	<b>,16 (.08)</b>	,14 (.07)	,53 (.26)	75,7%	<b>,92 (.09)</b>	,14 (.06)	,11 (.05)	,46 (.21)
	400	94,6%	6,7%	,87 (.10)	<b>,15 (.07)</b>	,13 (.07)	,51 (.25)	87,9%	<b>,93 (.06)</b>	,12 (.05)	<b>,10 (.04)</b>	,41 (.18)
	500	97,5%	4,0%	,91 (.06)	<b>,13 (.04)</b>	,11 (.04)	,42 (.13)	93,5%	<b>,94 (.07)</b>	,11 (.05)	<b>,09 (.04)</b>	,36 (.17)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del Modelo de Independencia; T1 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).



**Tabla 6.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

Distribución  $x N \times N$  Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	<b>,91 (,682)</b>	,93 (,14)	<b>1,00 (,15)</b>	,664 (,05)	<b>1,81 (,521)</b>	<b>1,64 (,39)</b>	<b>1,72 (,41)</b>	,91 (,14)
	300	<b>,82 (,699)</b>	,95 (,13)	<b>1,02 (,14)</b>	,661 (,04)	<b>1,85 (,517)</b>	<b>1,81 (,50)</b>	<b>1,89 (,52)</b>	,95 (,16)
	400	<b>,74 (,748)</b>	,97 (,11)	<b>1,06 (,12)</b>	,664 (,03)	<b>1,87 (,518)</b>	<b>2,00 (,59)</b>	<b>2,10 (,62)</b>	,99 (,18)
	500	<b>,86 (,700)</b>	<b>1,00 (,11)</b>	<b>1,07 (,12)</b>	,665 (,03)	<b>1,85 (,518)</b>	<b>2,24 (,68)</b>	<b>2,35 (,72)</b>	<b>1,05 (,21)</b>
RML	200	<b>,85 (,699)</b>	,93 (,14)	<b>1,00 (,15)</b>	,664 (,04)	<b>1,74 (,530)</b>	<b>1,65 (,39)</b>	<b>1,73 (,41)</b>	,91 (,14)
	300	<b>,81 (,702)</b>	,95 (,13)	<b>1,02 (,14)</b>	,661 (,04)	<b>1,83 (,522)</b>	<b>1,82 (,50)</b>	<b>1,90 (,52)</b>	,95 (,17)
	400	<b>,67 (,758)</b>	,98 (,11)	<b>1,06 (,12)</b>	,664 (,03)	<b>1,83 (,523)</b>	<b>2,01 (,59)</b>	<b>2,11 (,62)</b>	,99 (,18)
	500	<b>,83 (,709)</b>	<b>1,00 (,11)</b>	<b>1,08 (,12)</b>	,665 (,03)	<b>1,82 (,521)</b>	<b>2,25 (,68)</b>	<b>2,36 (,72)</b>	<b>1,05 (,21)</b>
RULS	200	<b>,90 (,684)</b>	,93 (,14)	<b>1,00 (,15)</b>	,664 (,04)	<b>1,82 (,521)</b>	<b>1,64 (,39)</b>	<b>1,72 (,41)</b>	,91 (,14)
	300	<b>,80 (,704)</b>	,95 (,13)	<b>1,03 (,14)</b>	,662 (,04)	<b>1,85 (,517)</b>	<b>1,81 (,50)</b>	<b>1,89 (,52)</b>	,95 (,16)
	400	<b>,73 (,748)</b>	,97 (,11)	<b>1,06 (,12)</b>	,664 (,03)	<b>1,86 (,519)</b>	<b>2,00 (,59)</b>	<b>2,10 (,62)</b>	,99 (,18)
	500	<b>,86 (,700)</b>	<b>1,00 (,11)</b>	<b>1,07 (,12)</b>	,665 (,03)	<b>1,85 (,519)</b>	<b>2,24 (,68)</b>	<b>2,35 (,72)</b>	<b>1,05 (,21)</b>
D2	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	<b>1,01 (,673)</b>	,92 (,15)	,99 (,16)	,660 (,05)	<b>1,78 (,522)</b>	<b>1,66 (,40)</b>	<b>1,73 (,42)</b>	,92 (,14)
	300	<b>1,15 (,636)</b>	,96 (,13)	<b>1,03 (,15)</b>	,664 (,04)	<b>1,85 (,518)</b>	<b>1,85 (,52)</b>	<b>1,93 (,54)</b>	,96 (,17)
	400	<b>,82 (,729)</b>	,98 (,13)	<b>1,06 (,15)</b>	,664 (,04)	<b>1,83 (,526)</b>	<b>2,05 (,60)</b>	<b>2,15 (,64)</b>	<b>1,00 (,19)</b>
	500	<b>,73 (,730)</b>	<b>1,00 (,11)</b>	<b>1,08 (,12)</b>	,666 (,03)	<b>1,82 (,522)</b>	<b>2,30 (,69)</b>	<b>2,41 (,73)</b>	<b>1,07 (,21)</b>
RML	200	<b>1,04 (,662)</b>	,91 (,15)	,97 (,17)	,657 (,05)	<b>1,83 (,527)</b>	<b>1,66 (,40)</b>	<b>1,74 (,43)</b>	,92 (,14)
	300	<b>1,17 (,626)</b>	,97 (,13)	<b>1,03 (,15)</b>	,666 (,04)	<b>1,77 (,528)</b>	<b>1,86 (,53)</b>	<b>1,94 (,55)</b>	,96 (,17)
	400	<b>,77 (,740)</b>	,97 (,14)	<b>1,05 (,17)</b>	,662 (,04)	<b>1,77 (,534)</b>	<b>2,06 (,60)</b>	<b>2,16 (,64)</b>	<b>1,01 (,19)</b>
	500	<b>,75 (,726)</b>	<b>1,00 (,11)</b>	<b>1,08 (,13)</b>	,666 (,03)	<b>1,79 (,527)</b>	<b>2,31 (,69)</b>	<b>2,42 (,74)</b>	<b>1,07 (,21)</b>
RULS	200	<b>1,06 (,665)</b>	,91 (,15)	,98 (,17)	,658 (,05)	<b>1,82 (,522)</b>	<b>1,66 (,40)</b>	<b>1,73 (,42)</b>	,92 (,14)
	300	<b>1,19 (,629)</b>	,96 (,13)	<b>1,03 (,15)</b>	,664 (,04)	<b>1,86 (,518)</b>	<b>1,85 (,52)</b>	<b>1,93 (,54)</b>	,96 (,17)
	400	<b>,79 (,738)</b>	,98 (,12)	<b>1,07 (,14)</b>	,667 (,04)	<b>1,82 (,529)</b>	<b>2,05 (,60)</b>	<b>2,15 (,64)</b>	<b>1,01 (,19)</b>
	500	<b>,83 (,709)</b>	<b>1,00 (,10)</b>	<b>1,08 (,11)</b>	,666 (,03)	<b>1,80 (,524)</b>	<b>2,30 (,69)</b>	<b>2,41 (,73)</b>	<b>1,07 (,21)</b>
D3	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	<b>,99 (,663)</b>	,92 (,14)	,98 (,15)	,658 (,05)	<b>1,84 (,520)</b>	<b>1,63 (,39)</b>	<b>1,71 (,42)</b>	,91 (,14)
	300	<b>1,11 (,646)</b>	,95 (,13)	<b>1,02 (,15)</b>	,661 (,04)	<b>1,87 (,511)</b>	<b>1,81 (,50)</b>	<b>1,89 (,52)</b>	,95 (,17)
	400	<b>,86 (,722)</b>	,95 (,13)	<b>1,03 (,15)</b>	,656 (,04)	<b>1,88 (,520)</b>	<b>2,00 (,59)</b>	<b>2,10 (,63)</b>	,99 (,18)
	500	<b>,76 (,722)</b>	,99 (,11)	<b>1,07 (,13)</b>	,662 (,03)	<b>1,87 (,516)</b>	<b>2,24 (,68)</b>	<b>2,34 (,73)</b>	<b>1,05 (,21)</b>
RML	200	<b>,96 (,673)</b>	,92 (,14)	,98 (,16)	,659 (,05)	<b>1,82 (,524)</b>	<b>1,64 (,39)</b>	<b>1,71 (,42)</b>	,91 (,14)
	300	<b>1,10 (,646)</b>	,95 (,13)	<b>1,02 (,15)</b>	,660 (,04)	<b>1,89 (,511)</b>	<b>1,82 (,51)</b>	<b>1,90 (,53)</b>	,95 (,17)
	400	<b>,77 (,737)</b>	,95 (,14)	<b>1,03 (,16)</b>	,655 (,04)	<b>1,88 (,521)</b>	<b>2,00 (,59)</b>	<b>2,10 (,63)</b>	,99 (,19)
	500	<b>,91 (,704)</b>	,98 (,12)	<b>1,06 (,14)</b>	,660 (,03)	<b>1,88 (,515)</b>	<b>2,24 (,68)</b>	<b>2,35 (,73)</b>	<b>1,05 (,21)</b>
RULS	200	<b>1,00 (,663)</b>	,92 (,14)	,98 (,15)	,658 (,05)	<b>1,85 (,521)</b>	<b>1,63 (,39)</b>	<b>1,71 (,41)</b>	,91 (,14)
	300	<b>1,08 (,652)</b>	,95 (,13)	<b>1,02 (,15)</b>	,661 (,04)	<b>1,88 (,510)</b>	<b>1,81 (,50)</b>	<b>1,89 (,52)</b>	,95 (,17)
	400	<b>,84 (,728)</b>	,96 (,13)	<b>1,03 (,15)</b>	,657 (,04)	<b>1,89 (,519)</b>	<b>2,00 (,59)</b>	<b>2,10 (,63)</b>	,99 (,18)
	500	<b>,76 (,722)</b>	,99 (,11)	<b>1,07 (,13)</b>	,662 (,03)	<b>1,87 (,516)</b>	<b>2,24 (,68)</b>	<b>2,35 (,73)</b>	<b>1,05 (,21)</b>

$\chi^2_0 (p-v)$  - Media (nivel crítico).

ECVI<sub>r</sub>, AIC<sub>r</sub>, CAIC<sub>r</sub> - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0; p \geq 0,05$ ) y las celdas en las que el valor ECVI, AIC o CAIC del modelo nulo es mayor que el del modelo evaluado (razón > 1).

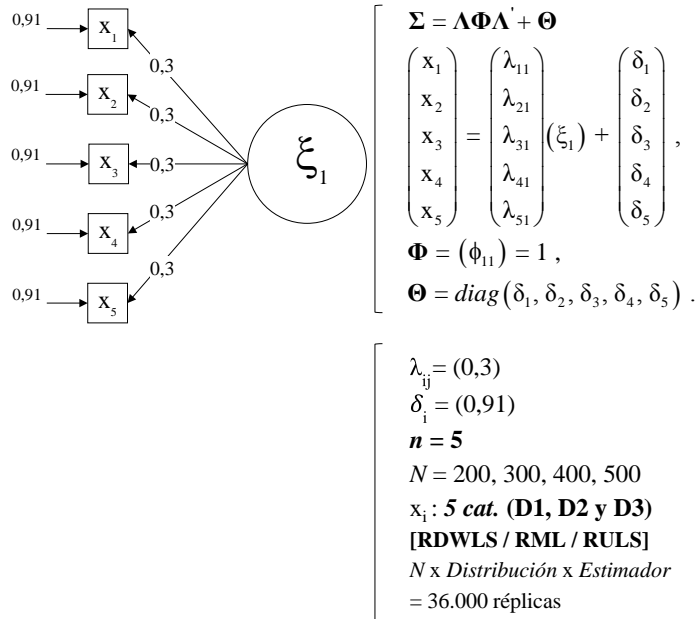
**Tabla 6.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.01)	,02 (.01)	,90 (.08)	1,85 (**)	,69 (.25)	,84 (.34)	,02 (.03)	,03 (.01)	,92 (.07)	1,14 (.35)	,76 (.22)	,97 (.06)
	300	,00 (.01)	,02 (.00)	,91 (.08)	1,75 (**)	,72 (.24)	,87 (.32)	,02 (.03)	,02 (.01)	,93 (.06)	1,11 (.31)	,78 (.20)	,97 (.06)
	400	,00 (.01)	,01 (.00)	,93 (.09)	1,98 (2,16)	,78 (.27)	,93 (.24)	,01 (.02)	,02 (.01)	,93 (.06)	1,09 (.27)	,80 (.19)	,97 (.05)
	500	,00 (.01)	,01 (.00)	,92 (.07)	1,87 (**)	,75 (.23)	,94 (.22)	,01 (.02)	,02 (.00)	,94 (.05)	1,08 (.23)	,83 (.17)	,98 (.04)
RML	200	,00 (.01)	,02 (.00)	,90 (.08)	1,86 (**)	,71 (.24)	,84 (.35)	,02 (.03)	,03 (.01)	,92 (.06)	1,14 (.33)	,77 (.21)	,97 (.06)
	300	,00 (.01)	,02 (.00)	,91 (.08)	1,75 (**)	,72 (.24)	,87 (.33)	,02 (.03)	,02 (.01)	,93 (.06)	1,11 (.30)	,79 (.19)	,97 (.05)
	400	,00 (.01)	,01 (.00)	,93 (.07)	2,00 (2,16)	,80 (.23)	,93 (.24)	,01 (.02)	,02 (.01)	,93 (.06)	1,09 (.26)	,80 (.19)	,98 (.05)
	500	,00 (.01)	,01 (.00)	,92 (.07)	1,87 (**)	,76 (.23)	,93 (.22)	,01 (.02)	,02 (.00)	,94 (.05)	1,08 (.23)	,83 (.17)	,98 (.04)
RULS	200	,00 (.01)	,02 (.01)	,90 (.08)	1,85 (**)	,69 (.26)	,84 (.35)	,02 (.03)	,03 (.01)	,92 (.07)	1,14 (.35)	,76 (.22)	,97 (.06)
	300	,00 (.01)	,02 (.00)	,91 (.07)	1,75 (**)	,73 (.23)	,87 (.33)	,02 (.03)	,02 (.01)	,93 (.06)	1,11 (.31)	,78 (.20)	,97 (.06)
	400	,00 (.01)	,01 (.00)	,93 (.09)	1,98 (2,16)	,78 (.27)	,93 (.24)	,01 (.02)	,02 (.01)	,93 (.06)	1,09 (.27)	,80 (.19)	,97 (.05)
	500	,00 (.01)	,01 (.00)	,92 (.07)	1,87 (**)	,75 (.23)	,94 (.22)	,01 (.02)	,02 (.00)	,94 (.05)	1,08 (.24)	,83 (.17)	,98 (.05)
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,01 (.02)	,02 (.01)	,88 (.11)	1,77 (9,76)	,65 (.36)	,79 (.39)	,02 (.03)	,03 (.01)	,92 (.07)	1,13 (.35)	,76 (.22)	,97 (.07)
	300	,01 (.02)	,02 (.01)	,87 (.15)	1,72 (9,18)	,60 (.47)	,86 (.34)	,02 (.03)	,02 (.01)	,93 (.07)	1,10 (.32)	,78 (.21)	,97 (.07)
	400	,00 (.01)	,01 (.00)	,91 (.12)	1,93 (2,13)	,74 (.36)	,89 (.30)	,01 (.02)	,02 (.01)	,94 (.07)	1,09 (.30)	,81 (.21)	,97 (.07)
	500	,00 (.01)	,01 (.00)	,93 (.07)	1,94 (**)	,78 (.21)	,98 (.05)	,01 (.02)	,02 (.00)	,94 (.06)	1,08 (.24)	,83 (.18)	,98 (.05)
RML	200	,01 (.02)	,02 (.01)	,87 (.12)	1,73 (**)	,62 (.39)	,76 (.41)	,02 (.03)	,03 (.01)	,92 (.09)	1,13 (.41)	,76 (.27)	,97 (.10)
	300	,01 (.02)	,02 (.01)	,87 (.14)	1,71 (3,16)	,60 (.44)	,86 (.33)	,02 (.03)	,02 (.01)	,93 (.07)	1,11 (.35)	,79 (.23)	,97 (.08)
	400	,00 (.01)	,01 (.00)	,91 (.15)	1,92 (2,16)	,72 (.45)	,88 (.30)	,01 (.02)	,02 (.01)	,94 (.06)	1,10 (.29)	,81 (.20)	,98 (.07)
	500	,00 (.01)	,01 (.00)	,93 (.07)	1,92 (**)	,78 (.22)	,98 (.06)	,01 (.02)	,02 (.00)	,94 (.06)	1,08 (.25)	,83 (.19)	,98 (.06)
RULS	200	,01 (.02)	,02 (.01)	,87 (.13)	1,74 (**)	,62 (.41)	,76 (.41)	,02 (.03)	,03 (.01)	,92 (.08)	1,13 (.40)	,76 (.25)	,96 (.09)
	300	,01 (.02)	,02 (.01)	,86 (.16)	1,71 (9,09)	,58 (.49)	,85 (.34)	,02 (.03)	,02 (.01)	,93 (.07)	1,11 (.33)	,78 (.22)	,97 (.07)
	400	,00 (.01)	,01 (.00)	,92 (.10)	1,93 (2,19)	,77 (.31)	,91 (.26)	,01 (.02)	,02 (.01)	,94 (.07)	1,10 (.31)	,81 (.22)	,97 (.07)
	500	,00 (.01)	,01 (.00)	,92 (.07)	1,92 (**)	,76 (.23)	,98 (.06)	,01 (.02)	,02 (.00)	,94 (.06)	1,08 (.24)	,83 (.18)	,98 (.05)
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,01 (.02)	,02 (.01)	,88 (.11)	1,73 (**)	,64 (.34)	,78 (.40)	,02 (.03)	,03 (.01)	,92 (.07)	1,14 (.37)	,75 (.24)	,96 (.07)
	300	,01 (.02)	,02 (.01)	,87 (.14)	1,71 (**)	,62 (.42)	,84 (.34)	,02 (.03)	,02 (.01)	,93 (.06)	1,10 (.32)	,78 (.21)	,97 (.06)
	400	,00 (.01)	,01 (.00)	,90 (.13)	1,92 (3,22)	,70 (.40)	,83 (.35)	,01 (.02)	,02 (.01)	,93 (.07)	1,09 (.31)	,79 (.22)	,97 (.07)
	500	,00 (.01)	,01 (.00)	,92 (.07)	1,88 (4,37)	,77 (.22)	,93 (.23)	,01 (.02)	,02 (.00)	,94 (.06)	1,08 (.25)	,82 (.18)	,98 (.05)
RML	200	,00 (.02)	,02 (.01)	,88 (.11)	1,78 (**)	,65 (.36)	,78 (.40)	,02 (.03)	,03 (.01)	,92 (.07)	1,14 (.37)	,76 (.23)	,97 (.07)
	300	,01 (.02)	,02 (.01)	,87 (.13)	1,70 (**)	,62 (.42)	,84 (.35)	,02 (.03)	,02 (.01)	,92 (.07)	1,10 (.36)	,77 (.23)	,97 (.08)
	400	,00 (.01)	,01 (.00)	,90 (.13)	1,93 (3,28)	,71 (.42)	,83 (.36)	,01 (.02)	,02 (.01)	,93 (.07)	1,09 (.31)	,79 (.22)	,97 (.07)
	500	,00 (.01)	,01 (.00)	,90 (.13)	1,87 (4,54)	,71 (.40)	,88 (.31)	,01 (.02)	,02 (.00)	,94 (.06)	1,08 (.27)	,82 (.19)	,98 (.06)
RULS	200	,01 (.02)	,02 (.01)	,88 (.11)	1,75 (**)	,64 (.35)	,78 (.40)	,02 (.03)	,03 (.01)	,92 (.08)	1,14 (.38)	,75 (.24)	,96 (.08)
	300	,01 (.02)	,02 (.01)	,88 (.13)	1,71 (**)	,63 (.42)	,85 (.34)	,02 (.03)	,02 (.01)	,93 (.06)	1,10 (.32)	,78 (.21)	,97 (.06)
	400	,00 (.01)	,01 (.00)	,91 (.12)	1,94 (3,25)	,72 (.37)	,84 (.34)	,01 (.02)	,02 (.01)	,93 (.07)	1,09 (.31)	,79 (.22)	,97 (.07)
	500	,00 (.01)	,01 (.00)	,92 (.07)	1,88 (4,37)	,77 (.22)	,93 (.23)	,01 (.02)	,02 (.00)	,94 (.06)	1,08 (.25)	,82 (.18)	,98 (.05)

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

Ficha 7. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3$ ,  $n = 5$ )

**Cuadro 7.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 7.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución x  $N$  x Estimador.

Distribución	$N$	IM ( $\lambda_{ij} = 0,3; n = 5$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,3; n = 5$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,3; n = 5$ )		
		RDWLS	RML	RULS	RDWLS	RML	RULS	RDWLS	RML	RULS
D1	200	7,8%	11,9%	7,4%	14,6%	13,4%	14,9%	77,6%	74,7%	77,7%
	300	2,5%	4,1%	2,6%	5,6%	5,3%	5,6%	91,9%	90,6%	91,8%
	400	1,4%	2,3%	1,5%	1,2%	1,2%	1,2%	97,4%	96,5%	97,3%
	500	0,3%	0,8%	0,5%	0,6%	0,6%	0,6%	99,1%	98,6%	98,9%
D2	200	25,6%	37,5%	26,5%	11,2%	9,0%	11,0%	63,2%	53,5%	62,5%
	300	16,5%	25,3%	17,2%	4,0%	3,2%	3,9%	79,5%	71,5%	78,9%
	400	9,6%	17,7%	10,2%	1,4%	1,3%	1,4%	89,0%	81,0%	88,4%
	500	7,3%	11,7%	7,9%	0,5%	0,5%	0,5%	92,2%	87,8%	91,6%
D3	200	8,3%	13,1%	8,4%	14,4%	13,3%	14,5%	77,3%	73,6%	77,1%
	300	2,8%	4,3%	2,7%	5,8%	5,8%	5,9%	91,4%	89,9%	91,4%
	400	1,3%	2,5%	1,3%	1,7%	1,6%	1,7%	97,0%	95,9%	97,0%
	500	0,4%	1,1%	0,4%	0,7%	0,7%	0,7%	98,9%	98,2%	98,9%

IM- Soluciones impropias (no convergentes/casos *Heywood*).

D1, D2 y D3: Caso 1, 4 y 6 (Muthén y Kaplan, 1992).

**Tabla 7.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null} (\alpha = 0,05)$ . Distribución x N x Estimador (Media (D.T.))

D1	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	92,2%	14,6%	,80 (.22)	<b>,18 (.09)</b>	,16 (.08)	,61 (.29)	77,6%	,88 (.22)	<b>,16 (.08)</b>	,13 (.07)	,52 (.27)
	300	97,5%	5,6%	,84 (.16)	<b>,16 (.07)</b>	,14 (.07)	,52 (.24)	91,9%	<b>,93 (.08)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,40 (.16)
	400	98,6%	1,2%	,89 (.07)	<b>,14 (.04)</b>	,12 (.04)	,46 (.12)	97,4%	<b>,94 (.09)</b>	<b>,11 (.04)</b>	<b>,09 (.04)</b>	,35 (.15)
	500	99,7%	0,6%	,90 (.09)	<b>,13 (.04)</b>	,11 (.04)	,43 (.15)	99,1%	<b>,95 (.07)</b>	<b>,09 (.04)</b>	<b>,08 (.03)</b>	,31 (.13)
RML	200	88,1%	13,4%	,78 (.24)	<b>,19 (.09)</b>	,16 (.08)	,63 (.31)	74,7%	,88 (.20)	<b>,16 (.08)</b>	,13 (.07)	,53 (.26)
	300	95,9%	5,3%	,84 (.17)	<b>,16 (.07)</b>	,14 (.06)	,53 (.24)	90,6%	<b>,92 (.08)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,41 (.16)
	400	97,7%	1,2%	,88 (.07)	<b>,14 (.03)</b>	,12 (.04)	,47 (.12)	96,5%	<b>,94 (.08)</b>	<b>,11 (.04)</b>	<b>,09 (.04)</b>	,36 (.14)
	500	99,2%	0,6%	,89 (.10)	<b>,13 (.05)</b>	,12 (.05)	,45 (.16)	98,6%	<b>,95 (.04)</b>	<b>,10 (.04)</b>	<b>,08 (.03)</b>	,32 (.12)
RULS	200	92,6%	14,9%	,79 (.22)	<b>,19 (.09)</b>	,16 (.08)	,62 (.29)	77,7%	,89 (.20)	<b>,15 (.07)</b>	,13 (.07)	,51 (.25)
	300	97,4%	5,6%	,84 (.16)	<b>,16 (.07)</b>	,14 (.06)	,52 (.23)	91,8%	<b>,93 (.08)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,40 (.16)
	400	98,5%	1,2%	,89 (.06)	<b>,13 (.03)</b>	,11 (.03)	,45 (.11)	97,3%	<b>,94 (.08)</b>	<b>,11 (.04)</b>	<b>,09 (.04)</b>	,36 (.14)
	500	99,5%	0,6%	,90 (.09)	<b>,13 (.04)</b>	,12 (.04)	,43 (.15)	98,9%	<b>,95 (.07)</b>	<b>,09 (.04)</b>	<b>,08 (.03)</b>	,31 (.13)
D2	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	74,4%	11,2%	,48 (.54)	,31 (.17)	,26 (.14)	1,03 (.55)	63,2%	,75 (.39)	,23 (.12)	,19 (.11)	,77 (.40)
	300	83,5%	4,0%	,66 (.37)	,24 (.13)	,20 (.11)	,80 (.44)	79,5%	,81 (.32)	<b>,19 (.10)</b>	,16 (.09)	,64 (.34)
	400	90,4%	1,4%	,60 (.50)	,24 (.14)	,20 (.13)	,80 (.45)	89,0%	,84 (.30)	<b>,17 (.10)</b>	,14 (.09)	,56 (.32)
	500	92,7%	0,5%	,35 (.63)	,31 (.18)	,27 (.15)	1,04 (.61)	92,2%	,89 (.21)	<b>,14 (.07)</b>	,12 (.07)	,48 (.25)
RML	200	62,5%	9,0%	,49 (.53)	,31 (.16)	,25 (.14)	1,02 (.52)	53,5%	,77 (.34)	,23 (.11)	,19 (.10)	,78 (.36)
	300	74,7%	3,2%	,67 (.34)	,24 (.12)	,20 (.10)	,79 (.39)	71,5%	,81 (.31)	,20 (.10)	,16 (.09)	,66 (.34)
	400	82,3%	1,3%	,57 (.51)	,25 (.14)	,21 (.13)	,83 (.46)	81,0%	,84 (.28)	<b>,17 (.09)</b>	,14 (.08)	,57 (.30)
	500	88,3%	0,5%	,48 (.47)	,28 (.14)	,24 (.10)	,92 (.45)	87,8%	,88 (.20)	<b>,15 (.07)</b>	,12 (.07)	,49 (.25)
RULS	200	73,5%	11,0%	,48 (.54)	,31 (.16)	,26 (.14)	1,02 (.53)	62,5%	,75 (.39)	,23 (.12)	,19 (.11)	,78 (.40)
	300	82,8%	3,9%	,64 (.38)	,25 (.13)	,21 (.11)	,83 (.44)	78,9%	,81 (.31)	<b>,19 (.10)</b>	,16 (.09)	,64 (.34)
	400	89,8%	1,4%	,59 (.50)	,24 (.14)	,20 (.12)	,81 (.45)	88,4%	,84 (.29)	<b>,17 (.09)</b>	,14 (.09)	,56 (.32)
	500	92,1%	0,5%	,35 (.65)	,31 (.18)	,27 (.14)	1,03 (.60)	91,6%	,89 (.20)	<b>,14 (.07)</b>	,12 (.06)	,48 (.24)
D3	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	91,7%	14,4%	,81 (.25)	<b>,17 (.08)</b>	,15 (.08)	,58 (.28)	77,3%	,87 (.25)	<b>,16 (.09)</b>	,13 (.08)	,52 (.29)
	300	97,2%	5,8%	,91 (.06)	<b>,13 (.04)</b>	<b>,10 (.03)</b>	,42 (.14)	91,4%	<b>,93 (.10)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,40 (.16)
	400	98,7%	1,7%	,78 (.34)	<b>,17 (.10)</b>	,14 (.09)	,57 (.33)	97,0%	<b>,94 (.08)</b>	<b>,10 (.04)</b>	<b>,09 (.04)</b>	,34 (.14)
	500	99,6%	0,7%	,88 (.12)	<b>,13 (.05)</b>	,11 (.05)	,44 (.18)	98,9%	<b>,95 (.09)</b>	<b>,09 (.04)</b>	<b>,08 (.04)</b>	,30 (.13)
RML	200	86,9%	13,3%	,81 (.22)	<b>,18 (.08)</b>	,15 (.08)	,59 (.28)	73,6%	,87 (.24)	<b>,16 (.08)</b>	,13 (.08)	,53 (.28)
	300	95,7%	5,8%	,90 (.07)	<b>,13 (.04)</b>	,11 (.04)	,43 (.14)	89,9%	<b>,92 (.10)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,41 (.17)
	400	97,5%	1,6%	,77 (.35)	<b>,18 (.11)</b>	,15 (.10)	,58 (.36)	95,9%	<b>,94 (.08)</b>	<b>,11 (.04)</b>	<b>,09 (.04)</b>	,35 (.14)
	500	98,9%	0,7%	,88 (.11)	<b>,13 (.05)</b>	,11 (.05)	,44 (.17)	98,2%	<b>,95 (.09)</b>	<b>,09 (.04)</b>	<b>,08 (.04)</b>	,31 (.14)
RULS	200	91,6%	14,5%	,80 (.29)	<b>,18 (.09)</b>	,15 (.09)	,59 (.31)	77,1%	,88 (.22)	<b>,15 (.08)</b>	,13 (.07)	,51 (.27)
	300	97,3%	5,9%	,90 (.07)	<b>,13 (.04)</b>	,11 (.04)	,42 (.14)	91,4%	<b>,93 (.10)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,40 (.16)
	400	98,7%	1,7%	,80 (.33)	<b>,16 (.09)</b>	,14 (.08)	,55 (.31)	97,0%	<b>,94 (.08)</b>	<b>,10 (.04)</b>	<b>,09 (.04)</b>	,34 (.14)
	500	99,6%	0,7%	,89 (.11)	<b>,13 (.05)</b>	,11 (.05)	,43 (.17)	98,9%	<b>,95 (.07)</b>	<b>,09 (.04)</b>	<b>,08 (.03)</b>	,30 (.13)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del Modelo de Independencia; T1 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

**Tabla 7.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

Distribución  $x N \times x$  Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	3,12 (,686)	,97 (,11)	1,07 (,13)	,698 (,04)	5,32 (,481)	1,63 (,38)	1,72 (,42)	,94 (,14)
	300	3,09 (,694)	,99 (,11)	1,09 (,13)	,693 (,04)	5,04 (,503)	1,87 (,49)	1,98 (,53)	1,01 (,18)
	400	2,92 (,701)	1,03 (,07)	1,13 (,12)	,698 (,03)	5,07 (,500)	2,15 (,59)	2,27 (,64)	1,08 (,20)
	500	2,93 (,708)	1,03 (,05)	1,14 (,11)	,694 (,02)	5,12 (,498)	2,45 (,67)	2,59 (,72)	1,17 (,22)
RML	200	3,08 (,695)	,97 (,11)	1,07 (,13)	,698 (,04)	5,21 (,489)	1,64 (,38)	1,74 (,42)	,95 (,14)
	300	2,88 (,716)	,99 (,11)	1,10 (,13)	,695 (,04)	4,97 (,507)	1,88 (,49)	1,99 (,53)	1,01 (,18)
	400	2,95 (,697)	1,03 (,07)	1,13 (,12)	,698 (,03)	5,04 (,502)	2,16 (,59)	2,28 (,64)	1,09 (,21)
	500	2,97 (,703)	1,03 (,05)	1,14 (,11)	,694 (,02)	5,12 (,498)	2,45 (,67)	2,59 (,72)	1,17 (,22)
RULS	200	3,19 (,680)	,97 (,11)	1,07 (,13)	,697 (,04)	5,36 (,478)	1,63 (,38)	1,72 (,42)	,94 (,14)
	300	3,15 (,692)	,99 (,11)	1,09 (,13)	,693 (,04)	5,04 (,502)	1,87 (,49)	1,98 (,53)	1,01 (,18)
	400	2,97 (,696)	1,03 (,07)	1,13 (,12)	,698 (,03)	5,08 (,500)	2,15 (,59)	2,27 (,64)	1,09 (,20)
	500	2,95 (,706)	1,03 (,05)	1,14 (,11)	,694 (,02)	5,13 (,497)	2,45 (,67)	2,59 (,72)	1,17 (,22)
D2	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	3,07 (,700)	,98 (,11)	1,08 (,13)	,700 (,04)	5,30 (,483)	1,65 (,40)	1,74 (,43)	,95 (,15)
	300	3,25 (,675)	,99 (,13)	1,09 (,14)	,693 (,04)	4,93 (,514)	1,89 (,50)	2,01 (,55)	1,01 (,18)
	400	4,72 (,548)	1,00 (,09)	1,08 (,16)	,686 (,04)	5,04 (,503)	2,19 (,59)	2,31 (,64)	1,10 (,20)
	500	3,46 (,631)	1,05 (,07)	1,13 (,12)	,694 (,03)	5,03 (,505)	2,49 (,67)	2,64 (,72)	1,18 (,22)
RML	200	3,26 (,689)	,98 (,10)	1,09 (,13)	,702 (,04)	5,14 (,498)	1,67 (,40)	1,77 (,44)	,96 (,15)
	300	3,34 (,665)	1,00 (,13)	1,09 (,15)	,694 (,04)	4,78 (,527)	1,91 (,51)	2,03 (,55)	1,02 (,18)
	400	3,88 (,596)	1,01 (,08)	1,10 (,15)	,690 (,03)	4,92 (,512)	2,21 (,59)	2,34 (,64)	1,11 (,21)
	500	3,49 (,627)	1,05 (,07)	1,13 (,12)	,695 (,03)	4,96 (,511)	2,51 (,67)	2,66 (,72)	1,19 (,22)
RULS	200	3,21 (,685)	,98 (,10)	1,08 (,13)	,701 (,04)	5,32 (,486)	1,65 (,39)	1,74 (,43)	,95 (,15)
	300	3,27 (,682)	,99 (,13)	1,09 (,15)	,692 (,04)	4,91 (,514)	1,89 (,50)	2,01 (,55)	1,01 (,18)
	400	4,72 (,546)	1,00 (,09)	1,08 (,16)	,686 (,04)	5,07 (,502)	2,19 (,59)	2,31 (,64)	1,10 (,20)
	500	3,48 (,628)	1,05 (,07)	1,13 (,12)	,695 (,03)	5,05 (,504)	2,50 (,67)	2,64 (,72)	1,18 (,22)
D3	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	3,29 (,671)	,97 (,11)	1,07 (,13)	,698 (,04)	5,34 (,479)	1,63 (,38)	1,72 (,42)	,94 (,14)
	300	3,27 (,670)	,99 (,11)	1,09 (,13)	,692 (,04)	5,04 (,502)	1,87 (,49)	1,98 (,54)	1,01 (,18)
	400	4,19 (,596)	1,00 (,09)	1,08 (,15)	,685 (,03)	5,09 (,500)	2,15 (,59)	2,27 (,64)	1,09 (,20)
	500	3,00 (,697)	1,05 (,06)	1,15 (,10)	,697 (,02)	5,13 (,498)	2,45 (,67)	2,59 (,72)	1,17 (,22)
RML	200	3,33 (,663)	,98 (,11)	1,07 (,13)	,699 (,04)	5,23 (,488)	1,64 (,39)	1,74 (,42)	,95 (,15)
	300	3,32 (,662)	,99 (,11)	1,09 (,13)	,692 (,04)	5,01 (,504)	1,88 (,49)	1,99 (,53)	1,01 (,18)
	400	3,85 (,623)	1,01 (,09)	1,09 (,14)	,689 (,03)	5,11 (,500)	2,16 (,60)	2,28 (,64)	1,09 (,21)
	500	3,03 (,694)	1,05 (,06)	1,15 (,10)	,697 (,02)	5,18 (,497)	2,45 (,68)	2,59 (,73)	1,17 (,22)
RULS	200	3,29 (,671)	,98 (,11)	1,07 (,13)	,699 (,04)	5,38 (,477)	1,63 (,38)	1,72 (,42)	,95 (,14)
	300	3,29 (,672)	,99 (,11)	1,08 (,13)	,690 (,04)	5,04 (,502)	1,87 (,49)	1,98 (,54)	1,01 (,18)
	400	4,21 (,592)	1,00 (,09)	1,08 (,15)	,685 (,03)	5,10 (,499)	2,15 (,59)	2,28 (,64)	1,09 (,20)
	500	3,02 (,695)	1,05 (,06)	1,15 (,10)	,697 (,02)	5,17 (,496)	2,45 (,68)	2,59 (,73)	1,17 (,22)

$\chi^2_0 (p-v)$  - Media (nivel crítico).

ECVI<sub>r</sub>, AIC<sub>r</sub>, CAIC<sub>r</sub> – Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0; p \geq 0,05$ ) y las celdas en las que el valor ECVI, AIC o CAIC del modelo nulo es mayor que el del modelo evaluado (razón > 1).

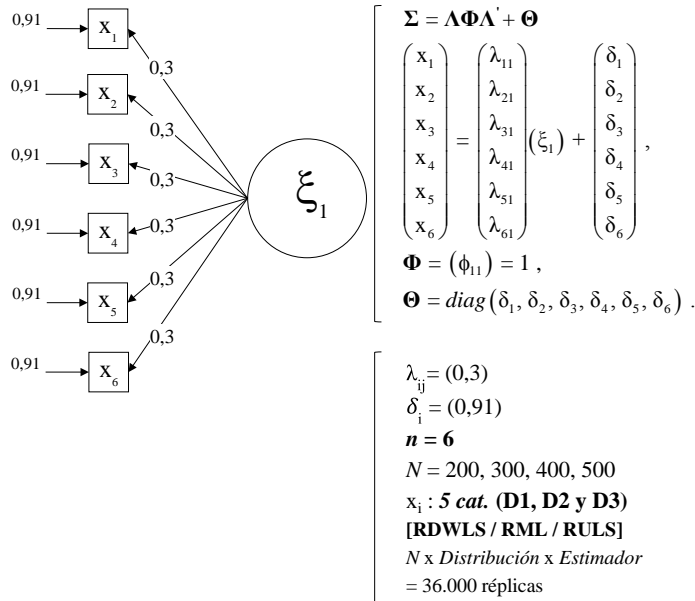
**Tabla 7.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.01)	,03 (.00)	,80 (.09)	1,82 (7,62)	,60 (.20)	,90 (.27)	,02 (.03)	,04 (.01)	,84 (.09)	1,07 (.31)	,69 (.19)	,95 (.08)
	300	,00 (.01)	,03 (.00)	,80 (.10)	1,79 (4,11)	,60 (.21)	,90 (.26)	,01 (.02)	,03 (.01)	,87 (.08)	1,06 (.25)	,74 (.16)	,96 (.07)
	400	,00 (.01)	,02 (.00)	,81 (.10)	1,72 (.83)	,62 (.21)	,99 (.03)	,01 (.02)	,03 (.00)	,89 (.07)	1,04 (.21)	,78 (.14)	,97 (.05)
	500	,00 (.00)	,02 (.00)	,82 (.09)	1,74 (.38)	,64 (.20)	1,0 (.00)	,01 (.02)	,03 (.00)	,90 (.06)	1,03 (.18)	,81 (.13)	,97 (.05)
RML	200	,00 (.01)	,03 (.00)	,81 (.10)	1,90 (7,93)	,61 (.21)	,90 (.28)	,02 (.03)	,04 (.01)	,85 (.08)	1,07 (.30)	,70 (.18)	,96 (.08)
	300	,00 (.01)	,03 (.00)	,81 (.09)	1,80 (3,57)	,63 (.19)	,93 (.23)	,01 (.02)	,03 (.01)	,87 (.07)	1,06 (.24)	,74 (.16)	,97 (.06)
	400	,00 (.01)	,02 (.00)	,81 (.10)	1,72 (.83)	,62 (.21)	,99 (.04)	,01 (.02)	,03 (.00)	,89 (.06)	1,05 (.20)	,78 (.14)	,97 (.05)
	500	,00 (.00)	,02 (.00)	,82 (.09)	1,74 (.37)	,64 (.19)	1,0 (.00)	,01 (.02)	,03 (.00)	,90 (.06)	1,03 (.18)	,81 (.13)	,97 (.05)
RULS	200	,00 (.01)	,03 (.00)	,80 (.10)	1,83 (7,54)	,60 (.21)	,90 (.28)	,02 (.03)	,04 (.01)	,84 (.09)	1,07 (.31)	,69 (.19)	,95 (.08)
	300	,00 (.01)	,03 (.00)	,80 (.11)	1,79 (4,11)	,60 (.22)	,90 (.27)	,01 (.02)	,03 (.01)	,87 (.08)	1,06 (.24)	,74 (.16)	,96 (.07)
	400	,00 (.01)	,02 (.00)	,81 (.10)	1,71 (.83)	,62 (.21)	,99 (.04)	,01 (.02)	,03 (.00)	,89 (.06)	1,04 (.21)	,78 (.14)	,97 (.05)
	500	,00 (.00)	,02 (.00)	,82 (.09)	1,74 (.37)	,64 (.19)	1,0 (.00)	,01 (.02)	,03 (.00)	,90 (.06)	1,03 (.18)	,81 (.13)	,97 (.05)
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.01)	,03 (.01)	,80 (.11)	1,83 (**)	,61 (.24)	,89 (.29)	,02 (.03)	,04 (.01)	,84 (.09)	1,07 (.31)	,69 (.19)	,95 (.08)
	300	,00 (.01)	,03 (.00)	,79 (.10)	1,64 (3,38)	,58 (.21)	,87 (.31)	,01 (.02)	,03 (.01)	,87 (.08)	1,06 (.26)	,74 (.17)	,96 (.08)
	400	,01 (.02)	,03 (.01)	,70 (.22)	1,43 (1,14)	,41 (.44)	,77 (.38)	,01 (.02)	,03 (.00)	,89 (.06)	1,04 (.20)	,78 (.14)	,97 (.05)
	500	,00 (.00)	,02 (.00)	,79 (.09)	1,42 (.24)	,58 (.18)	1,0 (.00)	,01 (.02)	,03 (.00)	,91 (.06)	1,03 (.17)	,81 (.12)	,97 (.05)
RML	200	,00 (.02)	,03 (.01)	,80 (.13)	1,90 (**)	,60 (.27)	,90 (.28)	,02 (.03)	,04 (.01)	,85 (.09)	1,08 (.31)	,70 (.19)	,96 (.08)
	300	,00 (.01)	,03 (.00)	,79 (.11)	1,59 (1,56)	,57 (.22)	,87 (.31)	,01 (.02)	,03 (.01)	,88 (.08)	1,07 (.26)	,75 (.17)	,97 (.08)
	400	,01 (.02)	,03 (.01)	,74 (.18)	1,49 (.96)	,49 (.37)	,86 (.30)	,01 (.02)	,03 (.00)	,90 (.06)	1,05 (.19)	,79 (.13)	,97 (.05)
	500	,00 (.00)	,02 (.00)	,79 (.09)	1,43 (.24)	,58 (.18)	1,0 (.00)	,01 (.02)	,02 (.00)	,91 (.06)	1,04 (.17)	,82 (.12)	,98 (.05)
RULS	200	,00 (.01)	,03 (.01)	,80 (.12)	1,86 (**)	,60 (.25)	,91 (.27)	,02 (.03)	,04 (.01)	,84 (.09)	1,07 (.33)	,69 (.19)	,95 (.09)
	300	,00 (.01)	,03 (.00)	,79 (.11)	1,65 (3,44)	,58 (.22)	,86 (.32)	,01 (.02)	,03 (.01)	,87 (.08)	1,06 (.26)	,75 (.17)	,97 (.08)
	400	,01 (.02)	,03 (.01)	,70 (.22)	1,43 (1,14)	,41 (.44)	,77 (.38)	,01 (.02)	,03 (.00)	,89 (.07)	1,04 (.20)	,78 (.14)	,97 (.06)
	500	,00 (.00)	,02 (.00)	,79 (.09)	1,42 (.24)	,58 (.18)	1,0 (.00)	,01 (.02)	,03 (.00)	,91 (.06)	1,03 (.17)	,81 (.12)	,97 (.05)
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.01)	,03 (.01)	,79 (.12)	1,85 (7,66)	,58 (.25)	,90 (.27)	,02 (.03)	,04 (.01)	,84 (.09)	1,07 (.31)	,69 (.19)	,95 (.08)
	300	,00 (.01)	,03 (.00)	,79 (.11)	1,73 (4,73)	,59 (.22)	,89 (.27)	,01 (.02)	,03 (.01)	,87 (.08)	1,06 (.25)	,74 (.17)	,96 (.07)
	400	,01 (.02)	,03 (.01)	,73 (.19)	1,49 (1,34)	,46 (.39)	,84 (.34)	,01 (.02)	,03 (.00)	,89 (.07)	1,04 (.21)	,78 (.14)	,97 (.06)
	500	,00 (.00)	,02 (.00)	,82 (.08)	1,58 (.36)	,64 (.18)	1,0 (.00)	,01 (.02)	,03 (.00)	,90 (.06)	1,03 (.18)	,81 (.13)	,97 (.05)
RML	200	,00 (.01)	,03 (.01)	,79 (.13)	1,83 (7,94)	,57 (.26)	,90 (.28)	,02 (.03)	,04 (.01)	,85 (.09)	1,07 (.31)	,70 (.18)	,96 (.08)
	300	,00 (.01)	,03 (.00)	,79 (.11)	1,76 (4,04)	,58 (.24)	,90 (.26)	,01 (.02)	,03 (.01)	,87 (.08)	1,06 (.25)	,74 (.16)	,96 (.07)
	400	,01 (.02)	,03 (.01)	,75 (.17)	1,57 (1,24)	,51 (.34)	,89 (.28)	,01 (.02)	,03 (.01)	,89 (.07)	1,04 (.22)	,78 (.15)	,97 (.06)
	500	,00 (.00)	,02 (.00)	,82 (.08)	1,58 (.36)	,64 (.18)	1,0 (.00)	,01 (.02)	,03 (.00)	,90 (.07)	1,03 (.20)	,80 (.14)	,97 (.06)
RULS	200	,00 (.01)	,03 (.01)	,79 (.11)	1,83 (7,62)	,59 (.24)	,91 (.27)	,02 (.03)	,04 (.01)	,84 (.09)	1,07 (.31)	,69 (.19)	,95 (.08)
	300	,00 (.01)	,03 (.00)	,79 (.11)	1,73 (4,70)	,59 (.23)	,88 (.29)	,01 (.02)	,03 (.01)	,87 (.08)	1,06 (.25)	,74 (.17)	,96 (.07)
	400	,01 (.02)	,03 (.01)	,73 (.19)	1,50 (1,34)	,46 (.39)	,84 (.34)	,01 (.02)	,03 (.00)	,89 (.07)	1,04 (.21)	,78 (.14)	,97 (.06)
	500	,00 (.00)	,02 (.00)	,82 (.08)	1,58 (.36)	,64 (.18)	1,0 (.00)	,01 (.02)	,03 (.00)	,90 (.06)	1,03 (.19)	,80 (.14)	,97 (.06)

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

Ficha 8. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3$ ,  $n = 6$ )

**Cuadro 8.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 8.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución x N x Estimador.

Distribución	N	IM ( $\lambda_{ij} = 0,3; n = 6$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,3; n = 6$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,3; n = 6$ )		
		RDWLS	RML	RULS	RDWLS	RML	RULS	RDWLS	RML	RULS
D1	200	3,2%	6,5%	3,2%	7,0%	6,3%	7,0%	89,8%	87,2%	89,8%
	300	1,2%	2,1%	1,4%	2,1%	1,9%	2,1%	96,7%	96,0%	96,5%
	400	0,6%	1,0%	0,4%	0,4%	0,4%	0,4%	99,0%	98,6%	99,2%
	500	0,1%	0,3%	0,2%	0,1%	0,1%	0,1%	99,8%	99,6%	99,7%
D2	200	15,4%	30,9%	16,5%	5,3%	3,8%	5,2%	79,3%	65,3%	78,3%
	300	9,4%	20,2%	10,9%	1,8%	1,2%	1,7%	88,8%	78,6%	87,4%
	400	3,3%	8,2%	4,0%	0,4%	0,4%	0,4%	96,3%	91,4%	95,6%
	500	2,2%	4,2%	2,5%	0,1%	0,1%	0,1%	97,7%	95,7%	97,4%
D3	200	4,1%	7,4%	3,9%	6,3%	5,8%	6,4%	89,6%	86,8%	89,7%
	300	1,6%	3,7%	1,7%	2,0%	2,0%	2,0%	96,4%	94,3%	96,3%
	400	0,1%	0,5%	0,1%	0,4%	0,4%	0,4%	99,5%	99,1%	99,5%
	500	0,1%	0,1%	0,2%	0,1%	0,1%	0,1%	99,8%	99,8%	99,7%

IM- Soluciones impropias (no convergentes/casos Heywood).

D1, D2 y D3: Caso 1, 4 y 6 (Muthén y Kaplan, 1992).

**Tabla 8.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ). *Distribución x N x Estimador (Media (D.T.))*

<b>D1</b>	<i>N</i>	<i>SV</i>	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$				
			<i>T2</i>	<i>C<sub>j</sub></i>	<i>RMSD<sub>j</sub></i>	<i>ARB<sub>j</sub></i>	<i>AMSE<sub>j</sub></i>	<i>TI</i>	<i>C<sub>j</sub></i>	<i>RMSD<sub>j</sub></i>	<i>ARB<sub>j</sub></i>	<i>AMSE<sub>j</sub></i>
<i>RDWLS</i>	200	96,8%	7,0%	,78 (.33)	<b>,18 (.10)</b>	,15 (.09)	,59 (.34)	89,8%	,89 (.18)	<b>,14 (.06)</b>	,12 (.06)	,48 (.21)
	300	98,8%	2,1%	,84 (.11)	<b>,17 (.07)</b>	,14 (.06)	,55 (.22)	96,7%	<b>,93 (.13)</b>	<b>,11 (.05)</b>	<b>,10 (.05)</b>	,38 (.17)
	400	99,4%	0,4%	,88 (.09)	<b>,14 (.05)</b>	,12 (.05)	,46 (.17)	99,0%	<b>,95 (.07)</b>	<b>,10 (.03)</b>	<b>,08 (.03)</b>	,32 (.11)
	500	99,9%	0,1%	<b>,98 (.00)</b>	<b>,08 (.00)</b>	<b>,07 (.00)</b>	,28 (.00)	99,8%	<b>,96 (.03)</b>	<b>,09 (.03)</b>	<b>,07 (.02)</b>	,29 (.09)
<i>RML</i>	200	93,5%	6,3%	,79 (.30)	<b>,17 (.09)</b>	,15 (.09)	,58 (.30)	87,2%	,89 (.17)	<b>,15 (.06)</b>	,12 (.06)	,49 (.21)
	300	97,9%	1,9%	,85 (.10)	<b>,16 (.06)</b>	,14 (.05)	,53 (.20)	96,0%	<b>,92 (.13)</b>	<b>,12 (.05)</b>	<b>,10 (.05)</b>	,39 (.17)
	400	99,0%	0,4%	,88 (.09)	<b>,14 (.05)</b>	,12 (.05)	,46 (.17)	98,6%	<b>,95 (.07)</b>	<b>,10 (.04)</b>	<b>,08 (.03)</b>	,33 (.12)
	500	99,7%	0,1%	<b>,98 (.00)</b>	<b>,09 (.00)</b>	<b>,07 (.00)</b>	,29 (.00)	99,6%	<b>,96 (.03)</b>	<b>,09 (.03)</b>	<b>,07 (.02)</b>	,29 (.09)
<i>RULS</i>	200	96,8%	7,0%	,78 (.33)	<b>,18 (.10)</b>	,15 (.09)	,59 (.33)	89,8%	,89 (.18)	<b>,14 (.06)</b>	,12 (.06)	,47 (.21)
	300	98,6%	2,1%	,84 (.10)	<b>,16 (.06)</b>	,14 (.05)	,54 (.19)	96,5%	<b>,93 (.13)</b>	<b>,11 (.05)</b>	<b>,10 (.05)</b>	,38 (.17)
	400	99,6%	0,4%	,88 (.09)	<b>,14 (.05)</b>	,12 (.05)	,45 (.16)	99,2%	<b>,95 (.04)</b>	<b>,10 (.03)</b>	<b>,08 (.03)</b>	,32 (.10)
	500	99,8%	0,1%	<b>,98 (.00)</b>	<b>,09 (.00)</b>	<b>,07 (.00)</b>	,29 (.00)	99,7%	<b>,96 (.03)</b>	<b>,09 (.03)</b>	<b>,07 (.02)</b>	,29 (.09)
<b>D2</b>	<i>N</i>	<i>SV</i>	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$				
			<i>T2</i>	<i>C<sub>j</sub></i>	<i>RMSD<sub>j</sub></i>	<i>ARB<sub>j</sub></i>	<i>AMSE<sub>j</sub></i>	<i>TI</i>	<i>C<sub>j</sub></i>	<i>RMSD<sub>j</sub></i>	<i>ARB<sub>j</sub></i>	<i>AMSE<sub>j</sub></i>
<i>RDWLS</i>	200	84,6%	5,3%	,57 (.40)	,27 (.12)	,23 (.10)	,90 (.39)	79,3%	,73 (.41)	,23 (.12)	,19 (.11)	,76 (.41)
	300	90,6%	1,8%	,58 (.50)	,25 (.14)	,21 (.13)	,84 (.45)	88,8%	,82 (.30)	<b>,18 (.10)</b>	,15 (.09)	,61 (.32)
	400	96,7%	0,4%	,53 (.51)	,27 (.15)	,23 (.12)	,91 (.51)	96,3%	,86 (.26)	<b>,16 (.08)</b>	,13 (.07)	,52 (.27)
	500	97,8%	0,1%	,90 (.00)	<b>,13 (.00)</b>	,11 (.00)	,44 (.00)	97,7%	,89 (.24)	<b>,14 (.07)</b>	,11 (.07)	,45 (.25)
<i>RML</i>	200	69,1%	3,8%	,58 (.42)	,27 (.13)	,22 (.11)	,90 (.42)	65,3%	,75 (.36)	,23 (.11)	,19 (.10)	,76 (.36)
	300	79,8%	1,2%	,58 (.55)	,24 (.15)	,21 (.14)	,81 (.50)	78,6%	,82 (.27)	<b>,18 (.09)</b>	,15 (.08)	,61 (.30)
	400	91,8%	0,4%	,45 (.53)	,30 (.14)	,26 (.11)	1,01 (.48)	91,4%	,86 (.23)	<b>,16 (.08)</b>	,13 (.07)	,54 (.26)
	500	95,8%	0,1%	,90 (.00)	<b>,13 (.00)</b>	,11 (.00)	,43 (.00)	95,7%	,88 (.21)	<b>,14 (.07)</b>	,12 (.06)	,47 (.23)
<i>RULS</i>	200	83,5%	5,2%	,56 (.39)	,28 (.12)	,23 (.10)	,93 (.39)	78,3%	,73 (.40)	,23 (.12)	,19 (.11)	,76 (.40)
	300	89,1%	1,7%	,62 (.47)	,24 (.13)	,20 (.12)	,80 (.43)	87,4%	,82 (.29)	<b>,18 (.09)</b>	,15 (.09)	,61 (.32)
	400	96,0%	0,4%	,52 (.51)	,27 (.15)	,23 (.11)	,90 (.50)	95,6%	,86 (.24)	<b>,16 (.08)</b>	,13 (.07)	,52 (.27)
	500	97,5%	0,1%	,90 (.00)	<b>,13 (.00)</b>	,11 (.00)	,43 (.00)	97,4%	,89 (.22)	<b>,13 (.07)</b>	,11 (.06)	,45 (.23)
<b>D3</b>	<i>N</i>	<i>SV</i>	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$				
			<i>T2</i>	<i>C<sub>j</sub></i>	<i>RMSD<sub>j</sub></i>	<i>ARB<sub>j</sub></i>	<i>AMSE<sub>j</sub></i>	<i>TI</i>	<i>C<sub>j</sub></i>	<i>RMSD<sub>j</sub></i>	<i>ARB<sub>j</sub></i>	<i>AMSE<sub>j</sub></i>
<i>RDWLS</i>	200	95,9%	6,3%	,80 (.28)	<b>,17 (.09)</b>	,14 (.08)	,56 (.30)	89,6%	,89 (.18)	<b>,14 (.06)</b>	,12 (.06)	,47 (.21)
	300	98,4%	2,0%	,85 (.11)	<b>,16 (.05)</b>	,14 (.05)	,52 (.17)	96,4%	<b>,93 (.13)</b>	<b>,11 (.05)</b>	<b>,10 (.04)</b>	,38 (.17)
	400	99,9%	0,4%	<b>,93 (.04)</b>	<b>,11 (.03)</b>	<b>,09 (.03)</b>	,36 (.11)	99,5%	<b>,95 (.07)</b>	<b>,10 (.03)</b>	<b>,08 (.03)</b>	,32 (.12)
	500	99,9%	0,1%	<b>,95 (.00)</b>	<b>,09 (.00)</b>	<b>,07 (.00)</b>	,30 (.00)	99,8%	<b>,96 (.03)</b>	<b>,09 (.03)</b>	<b>,07 (.02)</b>	,28 (.09)
<i>RML</i>	200	92,6%	5,8%	,79 (.29)	<b>,17 (.09)</b>	,14 (.09)	,57 (.31)	86,8%	,89 (.18)	<b>,15 (.06)</b>	,12 (.06)	,49 (.21)
	300	96,3%	2,0%	,83 (.11)	<b>,17 (.05)</b>	,15 (.05)	,55 (.18)	94,3%	<b>,93 (.11)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,39 (.15)
	400	99,5%	0,4%	<b>,92 (.05)</b>	<b>,11 (.04)</b>	<b>,10 (.04)</b>	,37 (.12)	99,1%	<b>,95 (.04)</b>	<b>,10 (.03)</b>	<b>,08 (.03)</b>	,33 (.11)
	500	99,9%	0,1%	<b>,95 (.00)</b>	<b>,09 (.00)</b>	<b>,07 (.00)</b>	,32 (.00)	99,8%	<b>,96 (.03)</b>	<b>,09 (.03)</b>	<b>,07 (.02)</b>	,29 (.09)
<i>RULS</i>	200	96,1%	6,4%	,79 (.29)	<b>,17 (.09)</b>	,14 (.08)	,56 (.31)	89,7%	,89 (.17)	<b>,14 (.06)</b>	,12 (.05)	,47 (.20)
	300	98,3%	2,0%	,85 (.11)	<b>,16 (.05)</b>	,14 (.05)	,52 (.17)	96,3%	<b>,93 (.13)</b>	<b>,11 (.05)</b>	<b>,10 (.04)</b>	,38 (.16)
	400	99,9%	0,4%	<b>,93 (.04)</b>	<b>,11 (.03)</b>	<b>,09 (.03)</b>	,36 (.11)	99,5%	<b>,95 (.04)</b>	<b>,10 (.03)</b>	<b>,08 (.03)</b>	,32 (.10)
	500	99,8%	0,1%	<b>,95 (.00)</b>	<b>,09 (.00)</b>	<b>,07 (.00)</b>	,31 (.00)	99,7%	<b>,96 (.03)</b>	<b>,08 (.03)</b>	<b>,07 (.02)</b>	,28 (.09)

*SV* - % total de soluciones válidas (descontando no soluciones IM). *T2* - % soluciones en las que se mantiene  $H_0$  del *Modelo de Independencia*; *TI* - % soluciones en las que se rechaza  $H_0$  del *Modelo de Independencia*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).



**Tabla 8.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	6,29 (.691)	,99 (.09)	1,11 (.11)	,721 (.03)	9,96 (.449)	1,68 (.41)	1,78 (.46)	,99 (.16)
	300	5,33 (.768)	1,02 (.06)	1,17 (.08)	,726 (.02)	9,61 (.463)	2,02 (.52)	2,13 (.56)	1,09 (.20)
	400	5,14 (.761)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,42 (.481)	2,34 (.59)	2,48 (.64)	1,19 (.21)
	500	2,36 (.984)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,42 (.481)	2,71 (.69)	2,87 (.77)	1,31 (.24)
RML	200	6,30 (.693)	,99 (.08)	1,12 (.11)	,724 (.03)	9,84 (.456)	1,69 (.41)	1,79 (.45)	1,00 (.16)
	300	5,07 (.790)	1,02 (.06)	1,18 (.08)	,726 (.02)	9,60 (.464)	2,02 (.52)	2,13 (.56)	1,10 (.20)
	400	5,12 (.762)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,43 (.481)	2,34 (.59)	2,48 (.64)	1,20 (.21)
	500	2,35 (.985)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,42 (.481)	2,71 (.69)	2,87 (.76)	1,31 (.24)
RULS	200	6,37 (.684)	,99 (.09)	1,11 (.11)	,720 (.03)	9,96 (.449)	1,68 (.41)	1,78 (.45)	,99 (.16)
	300	5,33 (.768)	1,02 (.06)	1,17 (.08)	,726 (.02)	9,62 (.463)	2,02 (.52)	2,13 (.56)	1,09 (.20)
	400	5,15 (.760)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,43 (.480)	2,34 (.59)	2,48 (.65)	1,19 (.21)
	500	2,36 (.985)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,42 (.481)	2,71 (.69)	2,87 (.76)	1,31 (.24)
D2	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	6,40 (.678)	,98 (.10)	1,10 (.13)	,716 (.04)	9,84 (.457)	1,70 (.41)	1,81 (.46)	1,00 (.17)
	300	5,66 (.743)	1,04 (.05)	1,17 (.07)	,729 (.02)	9,55 (.469)	2,05 (.53)	2,16 (.57)	1,10 (.20)
	400	5,14 (.761)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,44 (.480)	2,35 (.59)	2,49 (.65)	1,20 (.22)
	500	2,36 (.984)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,36 (.483)	2,72 (.69)	2,89 (.76)	1,31 (.24)
RML	200	5,77 (.734)	,99 (.10)	1,13 (.13)	,725 (.04)	9,63 (.468)	1,74 (.43)	1,85 (.48)	1,02 (.17)
	300	5,40 (.770)	1,04 (.06)	1,18 (.05)	,730 (.01)	9,42 (.480)	2,08 (.53)	2,20 (.57)	1,12 (.20)
	400	5,12 (.762)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,53 (.480)	2,37 (.60)	2,51 (.65)	1,21 (.22)
	500	2,35 (.985)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,38 (.484)	2,73 (.69)	2,90 (.77)	1,32 (.24)
RULS	200	6,37 (.680)	,98 (.10)	1,10 (.13)	,716 (.04)	9,87 (.456)	1,71 (.41)	1,81 (.46)	1,00 (.17)
	300	5,55 (.753)	1,04 (.05)	1,17 (.08)	,728 (.02)	9,53 (.470)	2,05 (.53)	2,17 (.57)	1,11 (.20)
	400	5,15 (.760)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,46 (.479)	2,36 (.59)	2,49 (.65)	1,20 (.22)
	500	2,36 (.985)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,40 (.482)	2,72 (.69)	2,89 (.77)	1,31 (.24)
D3	N	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	6,44 (.673)	,98 (.10)	1,10 (.13)	,717 (.04)	9,95 (.450)	1,68 (.41)	1,78 (.46)	,99 (.16)
	300	5,28 (.771)	1,02 (.06)	1,16 (.08)	,724 (.02)	9,65 (.462)	2,02 (.52)	2,13 (.57)	1,09 (.20)
	400	5,14 (.761)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,42 (.481)	2,34 (.59)	2,47 (.65)	1,19 (.22)
	500	2,36 (.984)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,42 (.481)	2,71 (.69)	2,87 (.77)	1,31 (.24)
RML	200	6,44 (.676)	,99 (.09)	1,11 (.12)	,721 (.04)	9,89 (.454)	1,69 (.41)	1,79 (.46)	1,00 (.17)
	300	5,26 (.773)	1,02 (.06)	1,17 (.08)	,724 (.02)	9,63 (.464)	2,03 (.52)	2,14 (.57)	1,10 (.20)
	400	5,12 (.762)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,52 (.479)	2,34 (.60)	2,48 (.65)	1,19 (.22)
	500	2,35 (.985)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,44 (.481)	2,71 (.69)	2,87 (.77)	1,31 (.24)
RULS	200	6,59 (.661)	,98 (.10)	1,09 (.13)	,715 (.04)	9,99 (.449)	1,68 (.41)	1,78 (.46)	,99 (.16)
	300	5,28 (.771)	1,02 (.06)	1,16 (.08)	,724 (.02)	9,64 (.462)	2,02 (.52)	2,13 (.57)	1,09 (.20)
	400	5,15 (.760)	1,04 (.05)	1,20 (.12)	,725 (.02)	9,44 (.480)	2,34 (.59)	2,47 (.65)	1,19 (.22)
	500	2,36 (.985)	1,11 (.00)	1,40 (.00)	,766 (.00)	9,45 (.481)	2,71 (.69)	2,87 (.77)	1,31 (.24)

$\chi^2_0 (p-v)$  - Media (nivel crítico).

ECVI<sub>r</sub>, AIC<sub>r</sub>, CAIC<sub>r</sub> – Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0; p \geq 0,05$ ) y las celdas en las que el valor ECVI, AIC o CAIC del modelo nulo es mayor que el del modelo evaluado (razón > 1).

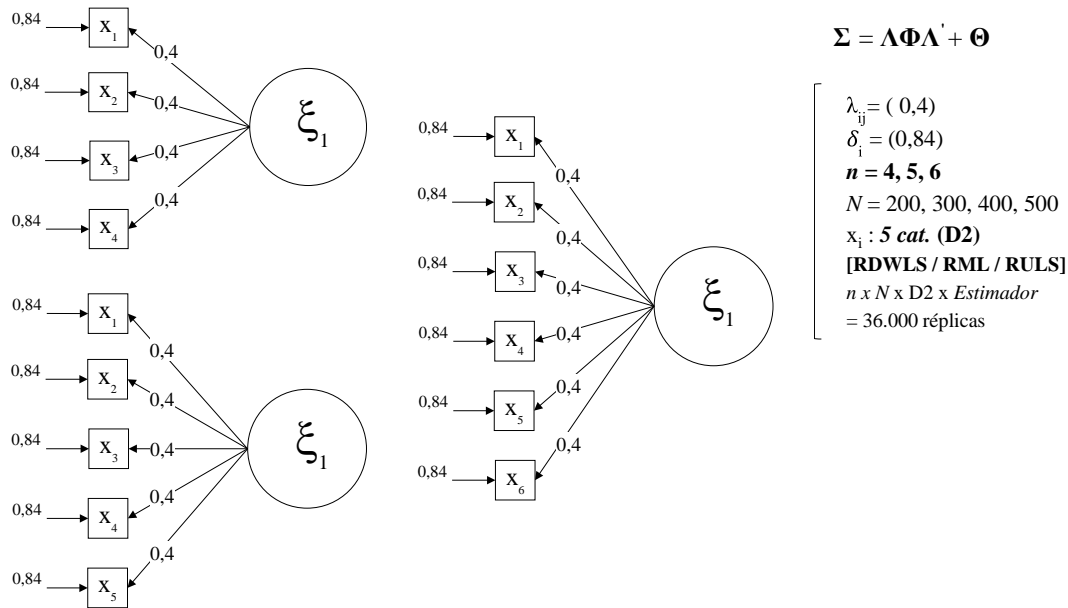
**Tabla 8.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 6)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (,00)	,04 (,00)	,74 (,10)	1,93 (**)	,56 (,17)	,94 (,23)	,02 (,02)	,05 (,01)	,80 (,09)	1,05 (,26)	,66 (,15)	,95 (,08)
	300	,00 (,00)	,03 (,00)	,78 (,09)	2,01 (1,19)	,63 (,16)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,07)	1,03 (,19)	,73 (,13)	,97 (,06)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,89)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,06)	1,02 (,16)	,77 (,11)	,97 (,05)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,13)	,81 (,10)	,97 (,04)
RML	200	,00 (,01)	,04 (,00)	,74 (,10)	1,94 (**)	,57 (,17)	,94 (,21)	,02 (,02)	,05 (,01)	,80 (,09)	1,06 (,26)	,67 (,15)	,96 (,07)
	300	,00 (,00)	,03 (,00)	,79 (,09)	2,03 (1,19)	,64 (,16)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,07)	1,03 (,19)	,73 (,13)	,97 (,06)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,89)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,06)	1,02 (,16)	,77 (,11)	,97 (,05)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,13)	,81 (,10)	,97 (,04)
RULS	200	,00 (,00)	,04 (,00)	,73 (,10)	1,90 (**)	,56 (,17)	,94 (,23)	,02 (,02)	,05 (,01)	,80 (,09)	1,05 (,26)	,67 (,15)	,95 (,07)
	300	,00 (,00)	,03 (,00)	,78 (,09)	2,01 (1,19)	,63 (,16)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,07)	1,03 (,19)	,73 (,13)	,97 (,06)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,90)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,06)	1,02 (,16)	,77 (,11)	,97 (,05)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,13)	,81 (,10)	,97 (,04)
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 6)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (,01)	,04 (,00)	,72 (,12)	1,87 (**)	,53 (,21)	,90 (,29)	,02 (,02)	,05 (,01)	,80 (,09)	1,06 (,26)	,67 (,15)	,96 (,08)
	300	,00 (,00)	,03 (,00)	,76 (,09)	1,86 (1,03)	,61 (,16)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,08)	1,03 (,20)	,73 (,14)	,97 (,07)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,89)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,07)	1,02 (,16)	,77 (,12)	,97 (,05)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,13)	,81 (,10)	,97 (,04)
RML	200	,00 (,00)	,04 (,00)	,75 (,10)	1,97 (**)	,59 (,17)	,95 (,22)	,02 (,02)	,05 (,01)	,81 (,09)	1,06 (,26)	,68 (,15)	,96 (,08)
	300	,00 (,00)	,03 (,00)	,77 (,07)	1,87 (1,17)	,62 (,13)	1,0 (,00)	,01 (,02)	,04 (,00)	,85 (,07)	1,03 (,20)	,74 (,13)	,97 (,06)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,89)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,07)	1,02 (,18)	,77 (,13)	,97 (,07)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,13)	,81 (,10)	,97 (,05)
RULS	200	,00 (,01)	,04 (,00)	,72 (,12)	1,79 (**)	,53 (,21)	,90 (,29)	,02 (,02)	,05 (,01)	,80 (,09)	1,05 (,26)	,67 (,15)	,96 (,08)
	300	,00 (,00)	,03 (,00)	,77 (,09)	1,93 (1,05)	,61 (,16)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,08)	1,03 (,20)	,73 (,13)	,97 (,07)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,90)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,07)	1,02 (,16)	,77 (,12)	,97 (,05)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,14)	,81 (,11)	,97 (,05)
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 6)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (,01)	,04 (,00)	,72 (,12)	1,75 (**)	,54 (,20)	,90 (,29)	,02 (,02)	,05 (,01)	,80 (,09)	1,05 (,27)	,66 (,16)	,95 (,08)
	300	,00 (,00)	,03 (,00)	,77 (,10)	2,02 (1,21)	,62 (,17)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,08)	1,03 (,20)	,73 (,14)	,96 (,07)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,89)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,07)	1,02 (,17)	,77 (,12)	,97 (,05)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,13)	,80 (,10)	,97 (,05)
RML	200	,00 (,01)	,04 (,00)	,73 (,12)	1,81 (**)	,54 (,20)	,93 (,25)	,02 (,02)	,05 (,01)	,80 (,09)	1,05 (,26)	,67 (,15)	,96 (,08)
	300	,00 (,00)	,03 (,00)	,77 (,09)	2,02 (1,20)	,62 (,17)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,08)	1,03 (,20)	,73 (,13)	,97 (,06)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,89)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,07)	1,02 (,18)	,77 (,13)	,97 (,07)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,14)	,80 (,11)	,97 (,05)
RULS	200	,00 (,01)	,04 (,01)	,71 (,12)	1,71 (**)	,52 (,21)	,89 (,29)	,02 (,02)	,05 (,01)	,80 (,09)	1,05 (,27)	,66 (,16)	,95 (,08)
	300	,00 (,00)	,03 (,00)	,77 (,10)	2,02 (1,21)	,62 (,17)	1,0 (,00)	,01 (,02)	,04 (,00)	,84 (,08)	1,03 (,20)	,73 (,13)	,96 (,06)
	400	,00 (,00)	,02 (,00)	,79 (,12)	2,07 (,90)	,66 (,20)	1,0 (,00)	,01 (,02)	,03 (,00)	,86 (,07)	1,02 (,17)	,77 (,12)	,97 (,05)
	500	,00 (,00)	,01 (,00)	,92 (,00)	2,21 (,00)	,86 (,00)	1,0 (,00)	,01 (,02)	,03 (,00)	,88 (,06)	1,02 (,14)	,80 (,11)	,97 (,05)

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

Ficha 9. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,4$ ,  $n = 4, 5, 6$ )

**Cuadro 9.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 9.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%).  $n \times N \times \text{Estimador}$ . Distribución 2.

$n$	$N$	IM ( $\lambda_{ij} = 0,4$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,4$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,4$ )		
		<i>RDWLS</i>	<i>RML</i>	<i>RULS</i>	<i>RDWLS</i>	<i>RML</i>	<i>RULS</i>	<i>RDWLS</i>	<i>RML</i>	<i>RULS</i>
4	200	15,2%	21,8%	16,2%	1,4%	1,4%	1,5%	83,4%	76,8%	82,3%
	300	6,8%	10,4%	6,7%	0,4%	0,4%	0,4%	92,8%	89,2%	92,9%
	400	2,8%	4,5%	3,1%	0,1%	0,1%	0,1%	97,1%	95,4%	96,8%
	500	0,9%	1,7%	0,9%	0,2%	0,2%	0,2%	98,9%	98,1%	98,9%
5	200	5,0%	11,5%	6,1%	0,3%	0,2%	0,3%	94,7%	88,3%	93,6%
	300	0,9%	3,0%	1,5%	0,0%	0,0%	0,0%	99,1%	97,0%	98,5%
	400	0,2%	0,7%	0,2%	0,0%	0,0%	0,0%	99,8%	99,3%	99,8%
	500	0,1%	0,2%	0,1%	0,0%	0,0%	0,0%	99,9%	99,8%	99,9%
6	200	2,0%	6,2%	2,2%	0,0%	0,0%	0,0%	98,0%	93,8%	97,8%
	300	0,3%	1,2%	0,4%	0,0%	0,0%	0,0%	99,7%	98,8%	99,6%
	400	0,0%	0,2%	0,1%	0,0%	0,0%	0,0%	100,0%	99,8%	99,9%
	500	0,0%	0,0%	0,0%	0,0%	0,0%	0,0%	100,0%	100,0%	100,0%

IM- Soluciones impropias (no convergentes/casos *Heywood*).  
Distribución 2: Caso 4 (Muthén y Kaplan, 1992).

**Tabla 9.2.** Ajuste teórico en función del resultado del test  $\chi^2_{\text{Null}} (\alpha = 0,05)$ .  $n \times N \times \text{Estimador}$  (Media (D.T.)) Distribución 2.

$n = 4$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$				
			$T2$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$TI$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
RDWLS	200	84,8%	1,4%	,83 (.23)	,21 (.09)	,18 (.08)	,53 (.22)	83,4%	,91 (.15)	<b>,18 (.08)</b>	,15 (.07)	,45 (.20)
	300	93,2%	0,4%	,78 (.07)	,28 (.05)	,24 (.06)	,69 (.13)	92,8%	<b>,93 (.12)</b>	<b>,15 (.07)</b>	,13 (.07)	,38 (.19)
	400	97,2%	0,1%	<b>,97 (.00)</b>	<b>,15 (.00)</b>	,14 (.00)	,38 (.00)	97,1%	<b>,95 (.05)</b>	<b>,13 (.06)</b>	,11 (.05)	,33 (.14)
	500	99,1%	0,2%	<b>,93 (.06)</b>	<b>,16 (.09)</b>	,13 (.07)	,39 (.22)	98,9%	<b>,96 (.04)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,29 (.12)
RML	200	78,2%	1,4%	,81 (.23)	,23 (.10)	,20 (.09)	,56 (.25)	76,8%	,91 (.13)	<b>,18 (.08)</b>	<b>,15 (.07)</b>	,46 (.20)
	300	89,6%	0,4%	,77 (.07)	,28 (.05)	,24 (.06)	,69 (.13)	89,2%	<b>,93 (.11)</b>	<b>,15 (.07)</b>	,13 (.06)	,39 (.18)
	400	95,5%	0,1%	<b>,97 (.00)</b>	<b>,15 (.00)</b>	,14 (.00)	,38 (.00)	95,4%	<b>,95 (.05)</b>	<b>,14 (.06)</b>	,11 (.05)	,34 (.14)
	500	98,3%	0,2%	<b>,93 (.06)</b>	<b>,16 (.09)</b>	,13 (.07)	,39 (.23)	98,1%	<b>,96 (.04)</b>	<b>,12 (.05)</b>	<b>,10 (.05)</b>	,30 (.13)
RULS	200	83,8%	1,5%	,82 (.23)	,22 (.10)	,20 (.09)	,56 (.25)	82,3%	,90 (.17)	<b>,18 (.09)</b>	,15 (.08)	,46 (.22)
	300	93,3%	0,4%	,78 (.07)	,27 (.05)	,23 (.06)	,69 (.14)	92,9%	<b>,93 (.11)</b>	<b>,15 (.07)</b>	,13 (.06)	,38 (.18)
	400	96,9%	0,1%	<b>,97 (.00)</b>	<b>,15 (.00)</b>	,14 (.00)	,38 (.00)	96,8%	<b>,95 (.05)</b>	<b>,13 (.06)</b>	,11 (.05)	,33 (.14)
	500	99,1%	0,2%	<b>,93 (.06)</b>	<b>,16 (.09)</b>	,13 (.07)	,39 (.23)	98,9%	<b>,96 (.04)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,29 (.13)
$n = 5$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$				
			$T2$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$TI$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
RDWLS	200	95,0%	0,3%	,80 (.08)	,21 (.05)	,21 (.04)	,60 (.10)	94,7%	,91 (.19)	<b>,15 (.08)</b>	,14 (.08)	,42 (.21)
	300	99,1%	0,0%	n.a.	n.a.	n.a.	n.a.	99,1%	<b>,94 (.15)</b>	<b>,12 (.06)</b>	,11 (.06)	,34 (.17)
	400	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,96 (.04)</b>	<b>,10 (.04)</b>	<b>,10 (.04)</b>	,29 (.10)
	500	99,9%	0,0%	n.a.	n.a.	n.a.	n.a.	99,9%	<b>,97 (.03)</b>	<b>,09 (.03)</b>	<b>,08 (.03)</b>	,25 (.09)
RML	200	88,5%	0,2%	,84 (.03)	<b>,19 (.05)</b>	,18 (.03)	,55 (.04)	88,3%	,90 (.18)	<b>,15 (.08)</b>	,15 (.08)	,44 (.21)
	300	97,0%	0,0%	n.a.	n.a.	n.a.	n.a.	97,0%	<b>,93 (.15)</b>	<b>,13 (.07)</b>	,12 (.06)	,36 (.17)
	400	99,3%	0,0%	n.a.	n.a.	n.a.	n.a.	99,3%	<b>,96 (.04)</b>	<b>,11 (.04)</b>	<b>,10 (.04)</b>	,30 (.11)
	500	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,97 (.03)</b>	<b>,09 (.04)</b>	<b>,09 (.03)</b>	,26 (.10)
RULS	200	93,9%	0,3%	,81 (.07)	,20 (.04)	,20 (.04)	,59 (.08)	93,6%	,90 (.20)	<b>,15 (.08)</b>	,15 (.08)	,43 (.22)
	300	98,5%	0,0%	n.a.	n.a.	n.a.	n.a.	98,5%	<b>,94 (.13)</b>	<b>,12 (.06)</b>	,11 (.06)	,34 (.16)
	400	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,96 (.04)</b>	<b>,10 (.04)</b>	<b>,10 (.04)</b>	,29 (.11)
	500	99,9%	0,0%	n.a.	n.a.	n.a.	n.a.	99,9%	<b>,97 (.03)</b>	<b>,09 (.03)</b>	<b>,09 (.03)</b>	,25 (.09)
$n = 6$	$N$	SV	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$				
			$T2$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$TI$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
RDWLS	200	98,0%	0,0%	n.a.	n.a.	n.a.	n.a.	98,0%	<b>,92 (.17)</b>	<b>,13 (.06)</b>	,13 (.07)	,39 (.19)
	300	99,7%	0,0%	n.a.	n.a.	n.a.	n.a.	99,7%	<b>,95 (.04)</b>	<b>,10 (.04)</b>	<b>,10 (.03)</b>	,31 (.10)
	400	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100,0%	<b>,96 (.06)</b>	<b>,09 (.04)</b>	<b>,09 (.04)</b>	,26 (.10)
	500	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100,0%	<b>,97 (.02)</b>	<b>,08 (.03)</b>	<b>,08 (.02)</b>	,23 (.07)
RML	200	93,8%	0,0%	n.a.	n.a.	n.a.	n.a.	93,8%	<b>,92 (.13)</b>	<b>,13 (.06)</b>	,14 (.06)	,41 (.16)
	300	98,8%	0,0%	n.a.	n.a.	n.a.	n.a.	98,8%	<b>,95 (.04)</b>	<b>,11 (.04)</b>	,11 (.04)	,33 (.11)
	400	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,96 (.06)</b>	<b>,09 (.04)</b>	<b>,09 (.04)</b>	,28 (.10)
	500	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100,0%	<b>,97 (.02)</b>	<b>,08 (.03)</b>	<b>,08 (.03)</b>	,24 (.08)
RULS	200	97,8%	0,0%	n.a.	n.a.	n.a.	n.a.	97,8%	<b>,92 (.12)</b>	<b>,13 (.05)</b>	,13 (.06)	,39 (.16)
	300	99,6%	0,0%	n.a.	n.a.	n.a.	n.a.	99,6%	<b>,95 (.04)</b>	<b>,10 (.04)</b>	<b>,10 (.04)</b>	,31 (.10)
	400	99,9%	0,0%	n.a.	n.a.	n.a.	n.a.	99,9%	<b>,96 (.06)</b>	<b>,09 (.04)</b>	<b>,09 (.04)</b>	,27 (.10)
	500	100,0%	0,0%	n.a.	n.a.	n.a.	n.a.	100,0%	<b>,97 (.02)</b>	<b>,08 (.03)</b>	<b>,08 (.03)</b>	,23 (.07)

SV - % total de soluciones válidas (descontando no soluciones IM).  $T2$  - % soluciones en las que se mantiene  $H_0$  del *Modelo de Independencia*;  $TI$  - % soluciones en las que se rechaza  $H_0$  del *Modelo de Independencia*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

n.a. - No aplicable.

**Tabla 9.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$n \times N \times$  Estimador (Media (D.T.) sobre soluciones válidas). Distribución 2.

$n = 4$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
RDWLS	200	<b>0,36 (,848)</b>	0,91 (0,14)	<b>1,00 (0,15)</b>	0,661 (0,05)	<b>1,86 (,521)</b>	<b>3,00 (1,09)</b>	<b>3,14 (1,15)</b>	<b>1,40 (0,39)</b>
	300	<b>0,36 (,856)</b>	0,80 (0,25)	0,87 (0,24)	0,614 (0,07)	<b>1,80 (,529)</b>	<b>3,76 (1,39)</b>	<b>3,94 (1,47)</b>	<b>1,60 (0,46)</b>
	400	<b>0,05 (,974)</b>	<b>1,13 (0,00)</b>	<b>1,27 (0,00)</b>	0,721 (0,00)	<b>1,88 (,518)</b>	<b>4,57 (1,55)</b>	<b>4,78 (1,62)</b>	<b>1,82 (0,49)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>1,88 (,513)</b>	<b>5,40 (1,79)</b>	<b>5,65 (1,89)</b>	<b>2,03 (0,55)</b>
RML	200	<b>0,33 (,861)</b>	0,92 (0,14)	<b>1,01 (0,15)</b>	0,665 (0,04)	<b>1,76 (,536)</b>	<b>3,05 (1,10)</b>	<b>3,19 (1,16)</b>	<b>1,41 (0,39)</b>
	300	<b>0,36 (,856)</b>	0,80 (0,25)	0,87 (0,24)	0,614 (0,07)	<b>1,69 (,541)</b>	<b>3,79 (1,40)</b>	<b>3,97 (1,48)</b>	<b>1,61 (0,46)</b>
	400	<b>0,05 (,974)</b>	<b>1,13 (0,00)</b>	<b>1,27 (0,00)</b>	0,721 (0,00)	<b>1,82 (,522)</b>	<b>4,59 (1,55)</b>	<b>4,80 (1,62)</b>	<b>1,82 (0,49)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>1,85 (,516)</b>	<b>5,40 (1,79)</b>	<b>5,66 (1,90)</b>	<b>2,03 (0,55)</b>
RULS	200	<b>0,41 (,834)</b>	0,92 (0,13)	<b>1,01 (0,14)</b>	0,665 (0,04)	<b>1,84 (,524)</b>	<b>3,01 (1,09)</b>	<b>3,16 (1,15)</b>	<b>1,40 (0,39)</b>
	300	<b>0,36 (,856)</b>	0,80 (0,25)	0,87 (0,24)	0,614 (0,07)	<b>1,79 (,529)</b>	<b>3,76 (1,40)</b>	<b>3,94 (1,47)</b>	<b>1,60 (0,46)</b>
	400	<b>0,05 (,974)</b>	<b>1,13 (0,00)</b>	<b>1,27 (0,00)</b>	0,721 (0,00)	<b>1,87 (,518)</b>	<b>4,57 (1,55)</b>	<b>4,79 (1,62)</b>	<b>1,82 (0,49)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>1,88 (,513)</b>	<b>5,40 (1,79)</b>	<b>5,65 (1,89)</b>	<b>2,03 (0,55)</b>
$n = 5$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
RDWLS	200	<b>1,63 (,884)</b>	<b>1,02 (,09)</b>	<b>1,19 (,14)</b>	,730 (,04)	<b>5,04 (,512)</b>	<b>3,35 (1,16)</b>	<b>3,55 (1,24)</b>	<b>1,60 (,44)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>5,02 (,503)</b>	<b>4,29 (1,40)</b>	<b>4,54 (1,52)</b>	<b>1,88 (,50)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>4,99 (,509)</b>	<b>5,24 (1,66)</b>	<b>5,54 (1,80)</b>	<b>2,16 (,57)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>4,95 (,517)</b>	<b>6,23 (1,84)</b>	<b>6,61 (2,02)</b>	<b>2,45 (,61)</b>
RML	200	<b>1,13 (,948)</b>	<b>1,06 (,10)</b>	<b>1,26 (,10)</b>	,749 (,03)	<b>4,86 (,529)</b>	<b>3,40 (1,18)</b>	<b>3,62 (1,25)</b>	<b>1,62 (,44)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>4,96 (,507)</b>	<b>4,33 (1,40)</b>	<b>4,58 (1,51)</b>	<b>1,89 (,50)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>4,99 (,510)</b>	<b>5,25 (1,66)</b>	<b>5,56 (1,80)</b>	<b>2,16 (,57)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>4,96 (,516)</b>	<b>6,24 (1,84)</b>	<b>6,62 (2,02)</b>	<b>2,45 (,61)</b>
RULS	200	<b>1,62 (,886)</b>	<b>1,02 (,09)</b>	<b>1,19 (,14)</b>	,730 (,04)	<b>5,01 (,515)</b>	<b>3,36 (1,16)</b>	<b>3,57 (1,24)</b>	<b>1,61 (,44)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>4,99 (,505)</b>	<b>4,30 (1,40)</b>	<b>4,55 (1,51)</b>	<b>1,89 (,50)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>5,00 (,509)</b>	<b>5,24 (1,66)</b>	<b>5,55 (1,80)</b>	<b>2,16 (,57)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>4,95 (,516)</b>	<b>6,23 (1,84)</b>	<b>6,61 (2,02)</b>	<b>2,45 (,61)</b>
$n = 6$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
RDWLS	200	n.a.	n.a.	n.a.	n.a.	<b>10,2 (,448)</b>	<b>3,66 (1,13)</b>	<b>3,88 (1,23)</b>	<b>1,80 (,46)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>9,58 (,471)</b>	<b>4,77 (1,44)</b>	<b>5,05 (1,56)</b>	<b>2,16 (,55)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>9,52 (,469)</b>	<b>5,90 (1,62)</b>	<b>6,23 (1,77)</b>	<b>2,51 (,59)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>9,49 (,478)</b>	<b>7,03 (1,86)</b>	<b>7,45 (2,05)</b>	<b>2,87 (,66)</b>
RML	200	n.a.	n.a.	n.a.	n.a.	<b>10,0 (,457)</b>	<b>3,70 (1,13)</b>	<b>3,94 (1,22)</b>	<b>1,82 (,46)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>9,61 (,470)</b>	<b>4,79 (1,43)</b>	<b>5,07 (1,55)</b>	<b>2,17 (,55)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>9,55 (,468)</b>	<b>5,91 (1,63)</b>	<b>6,24 (1,77)</b>	<b>2,52 (,59)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>9,51 (,477)</b>	<b>7,03 (1,86)</b>	<b>7,45 (2,05)</b>	<b>2,87 (,66)</b>
RULS	200	n.a.	n.a.	n.a.	n.a.	<b>10,2 (,448)</b>	<b>3,67 (1,13)</b>	<b>3,89 (1,23)</b>	<b>1,81 (,46)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>9,59 (,471)</b>	<b>4,77 (1,44)</b>	<b>5,06 (1,56)</b>	<b>2,16 (,55)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>9,53 (,469)</b>	<b>5,91 (1,63)</b>	<b>6,23 (1,77)</b>	<b>2,52 (,59)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>9,50 (,478)</b>	<b>7,03 (1,86)</b>	<b>7,45 (2,05)</b>	<b>2,87 (,66)</b>

$\chi^2_0 (p-v)$  - Media (nivel crítico).

$ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ ;  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.


**Tabla 9.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ). $n \times N \times$  Estimador (Media (D.T.) sobre soluciones válidas). Distribución 2.

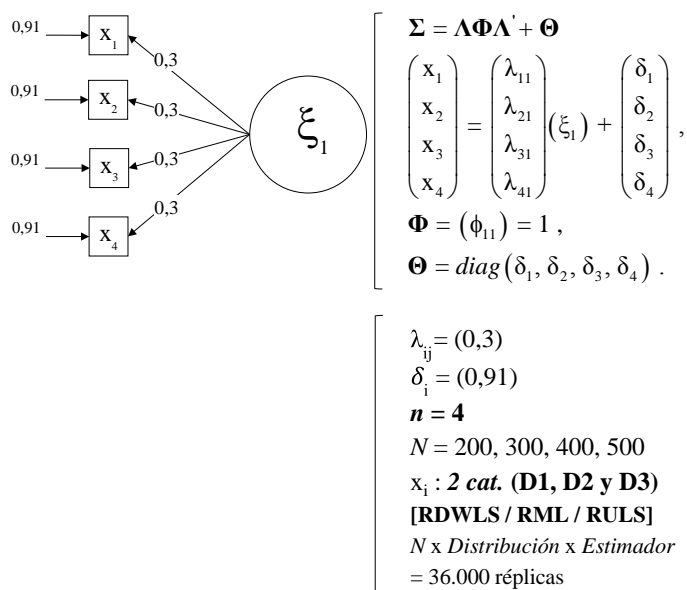
$n = 4$	$N$	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	<b>,00 (,00)</b>	<b>,02 (,01)</b>	,95 (,04)	2,24 (7,66)	,86 (,15)	,79 (,42)	<b>,02 (,03)</b>	<b>,04 (,02)</b>	,96 (,03)	1,05 (,16)	,88 (,11)	<b>,99 (,02)</b>
	300	<b>,00 (,00)</b>	<b>,01 (,01)</b>	,96 (,04)	-,8 (3,12)	,89 (,15)	,33 (,57)	<b>,02 (,03)</b>	<b>,03 (,01)</b>	,97 (,02)	1,04 (,13)	,91 (,09)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,97 (,02)	1,03 (,09)	,92 (,08)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,98 (,02)	1,02 (,07)	,93 (,07)	<b>,99 (,01)</b>
RML	200	<b>,00 (,00)</b>	<b>,02 (,01)</b>	,96 (,03)	2,24 (7,04)	,89 (,12)	,79 (,42)	<b>,02 (,03)</b>	<b>,04 (,02)</b>	,96 (,03)	1,06 (,15)	,89 (,10)	<b>,99 (,02)</b>
	300	<b>,00 (,00)</b>	<b>,01 (,01)</b>	,96 (,04)	-,8 (3,12)	,89 (,15)	,33 (,57)	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,97 (,02)	1,05 (,12)	,91 (,08)	<b>,99 (,01)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,98 (,02)	1,03 (,09)	,93 (,07)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,98 (,02)	1,02 (,07)	,94 (,06)	<b>,99 (,01)</b>
RULS	200	<b>,00 (,00)</b>	<b>,02 (,01)</b>	,95 (,04)	2,00 (6,78)	,86 (,15)	,80 (,41)	<b>,02 (,03)</b>	<b>,04 (,02)</b>	,96 (,03)	1,05 (,16)	,88 (,11)	<b>,99 (,02)</b>
	300	<b>,00 (,00)</b>	<b>,01 (,01)</b>	,96 (,04)	-,8 (3,12)	,89 (,15)	,33 (,57)	<b>,02 (,03)</b>	<b>,03 (,01)</b>	,97 (,02)	1,04 (,13)	,91 (,09)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,97 (,02)	1,03 (,09)	,92 (,07)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,98 (,02)	1,02 (,07)	,93 (,07)	<b>,99 (,01)</b>
$n = 5$	$N$	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	<b>,00 (,00)</b>	<b>,04 (,01)</b>	,90 (,06)	2,39 (4,46)	,80 (,14)	<b>1,0 (,00)</b>	<b>,02 (,03)</b>	<b>,06 (,01)</b>	,94 (,04)	1,03 (,13)	,87 (,08)	<b>,99 (,02)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,95 (,03)	1,02 (,08)	,90 (,07)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,96 (,02)	1,02 (,06)	,92 (,05)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,97 (,02)	1,02 (,05)	,93 (,05)	<b>,99 (,01)</b>
RML	200	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,94 (,00)	2,38 (,65)	,88 (,02)	<b>1,0 (,00)</b>	<b>,01 (,03)</b>	<b>,05 (,01)</b>	,94 (,03)	1,04 (,12)	,88 (,08)	<b>,99 (,02)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,95 (,03)	1,02 (,08)	,90 (,06)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,96 (,02)	1,02 (,06)	,92 (,05)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,97 (,02)	1,02 (,05)	,93 (,05)	<b>,99 (,01)</b>
RULS	200	<b>,00 (,00)</b>	<b>,04 (,01)</b>	,90 (,06)	2,40 (4,46)	,80 (,14)	<b>1,0 (,00)</b>	<b>,02 (,03)</b>	<b>,06 (,01)</b>	,94 (,04)	1,03 (,12)	,87 (,08)	<b>,99 (,02)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,95 (,03)	1,02 (,08)	,90 (,06)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,96 (,02)	1,02 (,06)	,92 (,05)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,97 (,02)	1,02 (,05)	,93 (,05)	<b>,99 (,01)</b>
$n = 6$	$N$	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,02 (,02)</b>	<b>,07 (,01)</b>	,92 (,04)	1,02 (,09)	,86 (,07)	<b>,98 (,02)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,94 (,03)	1,01 (,06)	,90 (,05)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,95 (,02)	1,01 (,04)	,92 (,04)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,96 (,02)	1,01 (,04)	,93 (,04)	<b>,99 (,01)</b>
RML	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,02 (,02)</b>	<b>,07 (,01)</b>	,92 (,03)	1,02 (,08)	,87 (,06)	<b>,99 (,02)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,94 (,03)	1,01 (,06)	,90 (,05)	<b>,99 (,01)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,95 (,02)	1,01 (,04)	,92 (,04)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,96 (,02)	1,01 (,04)	,93 (,04)	<b>,99 (,01)</b>
RULS	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,02 (,02)</b>	<b>,07 (,01)</b>	,92 (,04)	1,02 (,09)	,86 (,07)	<b>,98 (,02)</b>
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,94 (,03)	1,01 (,06)	,90 (,05)	<b>,99 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,95 (,02)	1,01 (,04)	,92 (,04)	<b>,99 (,01)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,96 (,02)	1,01 (,04)	,93 (,04)	<b>,99 (,01)</b>

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

n.a. – No aplicable.

## D. Datos dicotómicos



Ficha 10. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3$ ,  $n = 4$ )**Cuadro 10.1.** Path diagram, notación matricial y condiciones simuladas**Tabla 10.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución  $\times N \times \text{Estimador}$ .

Distribución	N	IM ( $\lambda_{ij} = 0,3; n = 4$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,3; n = 4$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,3; n = 4$ )		
		RDWLS	RML	RULS	RDWLS	RML	RULS	RDWLS	RML	RULS
D1	200	35,7%	42,7%	35,5%	10,8%	9,6%	10,8%	53,5%	47,7%	53,7%
	300	27,9%	32,4%	27,9%	6,6%	6,4%	6,6%	65,5%	61,2%	65,5%
	400	20,7%	25,2%	21,1%	3,0%	2,8%	3,0%	76,3%	72,0%	75,9%
	500	14,4%	17,3%	14,4%	2,0%	1,9%	2,0%	83,6%	80,8%	83,6%
D2	200	35,3%	42,0%	35,6%	11,1%	9,5%	11,1%	53,6%	48,5%	53,3%
	300	27,2%	33,4%	27,8%	7,0%	6,4%	7,0%	65,8%	60,2%	65,2%
	400	20,7%	25,5%	21,2%	3,8%	3,4%	3,8%	75,5%	71,1%	75,0%
	500	13,1%	17,3%	13,4%	2,3%	2,2%	2,3%	84,6%	80,5%	84,3%
D3	200	40,2%	49,4%	40,9%	10,1%	8,0%	10,1%	49,7%	42,6%	49,0%
	300	36,2%	43,2%	37,3%	6,5%	6,1%	6,3%	57,3%	50,7%	56,4%
	400	28,9%	34,0%	28,9%	4,5%	3,9%	4,4%	66,6%	62,1%	66,7%
	500	22,8%	26,7%	23,2%	2,5%	2,5%	2,5%	74,7%	70,8%	74,3%

IM- Soluciones impropias (no convergentes/casos Heywood).



**Tabla 10.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ). Distribución x N x Estimador (Media (D.T.))

D1	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	64,3%	10,8%	,68 (.35)	,24 (.12)	,20 (.11)	,80 (.40)	53,5%	,83 (.27)	,22 (.10)	,18 (.09)	,74 (.34)
	300	72,1%	6,6%	,71 (.32)	,22 (.11)	,19 (.09)	,74 (.36)	65,5%	,86 (.21)	<b>,19 (.09)</b>	,15 (.08)	,62 (.29)
	400	79,3%	3,0%	,80 (.18)	<b>,17 (.08)</b>	,15 (.08)	,58 (.26)	76,3%	,88 (.18)	<b>,16 (.08)</b>	,14 (.07)	,55 (.27)
	500	85,6%	2,0%	,84 (.11)	<b>,17 (.07)</b>	,15 (.06)	,56 (.22)	83,6%	,90 (.16)	<b>,15 (.08)</b>	,13 (.07)	,51 (.25)
RML	200	57,3%	9,6%	,69 (.35)	,24 (.12)	,20 (.11)	,79 (.40)	47,7%	,83 (.25)	,22 (.10)	,18 (.08)	,73 (.33)
	300	67,6%	6,4%	,71 (.33)	,22 (.11)	,19 (.09)	,74 (.35)	61,2%	,87 (.18)	<b>,19 (.08)</b>	,15 (.07)	,62 (.28)
	400	74,8%	2,8%	,81 (.17)	<b>,17 (.08)</b>	,15 (.08)	,58 (.26)	72,0%	,88 (.17)	<b>,17 (.08)</b>	,14 (.07)	,55 (.26)
	500	82,7%	1,9%	,85 (.10)	<b>,16 (.05)</b>	,14 (.06)	,54 (.18)	80,8%	,90 (.14)	<b>,15 (.07)</b>	,13 (.06)	,51 (.25)
RULS	200	64,5%	10,8%	,67 (.38)	,24 (.13)	,21 (.11)	,81 (.42)	53,7%	,83 (.25)	,22 (.10)	,18 (.08)	,73 (.33)
	300	72,1%	6,6%	,71 (.32)	,22 (.11)	,19 (.09)	,74 (.36)	65,5%	,86 (.22)	<b>,19 (.09)</b>	,15 (.08)	,62 (.30)
	400	78,9%	3,0%	,80 (.18)	<b>,17 (.08)</b>	,15 (.08)	,58 (.26)	75,9%	,88 (.18)	<b>,16 (.08)</b>	,14 (.07)	,55 (.27)
	500	85,6%	2,0%	,84 (.11)	<b>,17 (.07)</b>	,15 (.06)	,56 (.22)	83,6%	,90 (.16)	<b>,15 (.08)</b>	,13 (.07)	,51 (.26)
D2	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	64,7%	11,1%	,66 (.44)	,25 (.14)	,21 (.13)	,83 (.47)	53,6%	,82 (.28)	,22 (.10)	,18 (.09)	,73 (.33)
	300	72,8%	7,0%	,77 (.29)	,21 (.10)	,17 (.09)	,69 (.32)	65,8%	,84 (.27)	,20 (.10)	,16 (.09)	,66 (.34)
	400	79,3%	3,8%	,75 (.28)	,21 (.10)	,18 (.09)	,71 (.32)	75,5%	,88 (.18)	<b>,17 (.08)</b>	,14 (.07)	,56 (.27)
	500	86,9%	2,3%	,72 (.41)	,21 (.13)	,18 (.11)	,69 (.42)	84,6%	,89 (.15)	<b>,15 (.07)</b>	,13 (.06)	,52 (.24)
RML	200	58,0%	9,5%	,67 (.43)	,25 (.14)	,21 (.12)	,82 (.46)	48,5%	,82 (.28)	,22 (.10)	,18 (.09)	,75 (.34)
	300	66,6%	6,4%	,77 (.30)	,21 (.10)	,18 (.09)	,69 (.33)	60,2%	,84 (.26)	,20 (.10)	,16 (.08)	,66 (.33)
	400	74,5%	3,4%	,75 (.29)	,21 (.10)	,18 (.09)	,71 (.33)	71,1%	,88 (.15)	<b>,17 (.08)</b>	,14 (.06)	,56 (.25)
	500	82,7%	2,2%	,77 (.33)	,20 (.12)	,17 (.10)	,67 (.40)	80,5%	,89 (.15)	<b>,16 (.07)</b>	,13 (.06)	,52 (.24)
RULS	200	64,4%	11,1%	,66 (.44)	,25 (.14)	,21 (.13)	,83 (.47)	53,3%	,82 (.27)	,22 (.10)	,18 (.08)	,73 (.32)
	300	72,2%	7,0%	,77 (.29)	,21 (.10)	,17 (.09)	,69 (.32)	65,2%	,84 (.27)	,20 (.10)	,16 (.09)	,66 (.34)
	400	78,8%	3,8%	,75 (.28)	,21 (.10)	,18 (.09)	,71 (.32)	75,0%	,88 (.17)	<b>,17 (.08)</b>	,14 (.07)	,56 (.27)
	500	86,6%	2,3%	,72 (.41)	,21 (.13)	,18 (.11)	,69 (.42)	84,3%	,90 (.13)	<b>,15 (.07)</b>	,13 (.06)	,51 (.24)
D3	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	59,8%	10,1%	,60 (.49)	,30 (.15)	,24 (.13)	,99 (.51)	49,7%	,75 (.35)	,25 (.13)	,21 (.11)	,84 (.42)
	300	63,8%	6,5%	,69 (.45)	,25 (.15)	,20 (.13)	,82 (.48)	57,3%	,79 (.34)	,22 (.12)	,18 (.10)	,73 (.39)
	400	71,1%	4,5%	,72 (.40)	,23 (.13)	,20 (.12)	,77 (.43)	66,6%	,83 (.29)	<b>,19 (.10)</b>	,16 (.09)	,64 (.34)
	500	77,2%	2,5%	,63 (.54)	,24 (.15)	,21 (.14)	,80 (.51)	74,7%	,86 (.24)	<b>,18 (.10)</b>	,15 (.08)	,59 (.32)
RML	200	50,6%	8,0%	,60 (.50)	,29 (.15)	,24 (.13)	,96 (.51)	42,6%	,75 (.36)	,25 (.13)	,21 (.11)	,84 (.42)
	300	56,8%	6,1%	,68 (.46)	,25 (.15)	,20 (.13)	,82 (.49)	50,7%	,80 (.32)	,22 (.11)	,18 (.10)	,73 (.37)
	400	66,0%	3,9%	,76 (.35)	,22 (.12)	,19 (.11)	,75 (.41)	62,1%	,82 (.29)	,20 (.10)	,16 (.09)	,65 (.35)
	500	73,3%	2,5%	,63 (.53)	,25 (.15)	,21 (.14)	,82 (.51)	70,8%	,86 (.21)	<b>,18 (.09)</b>	,15 (.07)	,59 (.29)
RULS	200	59,1%	10,1%	,60 (.49)	,30 (.15)	,24 (.13)	,99 (.51)	49,0%	,75 (.36)	,25 (.13)	,21 (.11)	,84 (.42)
	300	62,7%	6,3%	,73 (.38)	,23 (.12)	,19 (.11)	,78 (.41)	56,4%	,79 (.34)	,22 (.12)	,18 (.10)	,74 (.39)
	400	71,1%	4,4%	,72 (.40)	,23 (.13)	,19 (.12)	,76 (.43)	66,7%	,82 (.30)	,20 (.11)	,16 (.09)	,66 (.36)
	500	76,8%	2,5%	,63 (.54)	,24 (.15)	,21 (.14)	,81 (.51)	74,3%	,86 (.24)	<b>,18 (.09)</b>	,15 (.08)	,59 (.31)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene H<sub>0</sub> del Modelo de Independencia; T1 - % soluciones en las que se rechaza H<sub>0</sub> del Modelo de Independencia.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones (C<sub>j</sub> ≥ 0,92, RMSD<sub>j</sub> < 0,2, ARB<sub>j</sub> ≤ 0,10 y AMSE<sub>j</sub> ≤ 0,10).

**Tabla 10.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	<b>,53 (,784)</b>	,94 (,15)	<b>1,02 (,15)</b>	,669 (,05)	<b>1,61 (,554)</b>	<b>2,03 (,70)</b>	<b>2,13 (,74)</b>	<b>1,05 (,25)</b>
	300	<b>,42 (,830)</b>	,96 (,12)	<b>1,05 (,12)</b>	,668 (,03)	<b>1,59 (,549)</b>	<b>2,29 (,82)</b>	<b>2,40 (,86)</b>	<b>1,10 (,27)</b>
	400	<b>,50 (,798)</b>	,91 (,16)	<b>1,00 (,17)</b>	,645 (,05)	<b>1,66 (,544)</b>	<b>2,51 (,96)</b>	<b>2,62 (1,00)</b>	<b>1,15 (,31)</b>
	500	<b>,38 (,834)</b>	,93 (,15)	<b>1,02 (,16)</b>	,646 (,04)	<b>1,71 (,542)</b>	<b>2,72 (1,01)</b>	<b>2,85 (1,06)</b>	<b>1,20 (,31)</b>
RML	200	<b>,49 (,798)</b>	,93 (,15)	<b>1,01 (,15)</b>	,666 (,05)	<b>1,46 (,578)</b>	<b>2,05 (,72)</b>	<b>2,16 (,76)</b>	<b>1,06 (,25)</b>
	300	<b>,41 (,832)</b>	,96 (,12)	<b>1,05 (,13)</b>	,668 (,04)	<b>1,50 (,564)</b>	<b>2,31 (,83)</b>	<b>2,43 (,87)</b>	<b>1,11 (,27)</b>
	400	<b>,49 (,803)</b>	,92 (,15)	<b>1,00 (,16)</b>	,646 (,04)	<b>1,58 (,556)</b>	<b>2,53 (,98)</b>	<b>2,66 (1,01)</b>	<b>1,16 (,31)</b>
	500	<b>,39 (,832)</b>	,93 (,15)	<b>1,02 (,16)</b>	,647 (,04)	<b>1,63 (,553)</b>	<b>2,73 (1,02)</b>	<b>2,87 (1,07)</b>	<b>1,20 (,32)</b>
RULS	200	<b>,53 (,784)</b>	,94 (,15)	<b>1,02 (,15)</b>	,669 (,05)	<b>1,60 (,553)</b>	<b>2,02 (,70)</b>	<b>2,12 (,74)</b>	<b>1,05 (,25)</b>
	300	<b>,42 (,830)</b>	,96 (,12)	<b>1,05 (,12)</b>	,668 (,03)	<b>1,61 (,548)</b>	<b>2,29 (,82)</b>	<b>2,40 (,86)</b>	<b>1,10 (,27)</b>
	400	<b>,50 (,798)</b>	,91 (,16)	<b>1,00 (,17)</b>	,645 (,05)	<b>1,63 (,546)</b>	<b>2,51 (,97)</b>	<b>2,63 (1,00)</b>	<b>1,15 (,31)</b>
	500	<b>,38 (,834)</b>	,93 (,15)	<b>1,02 (,16)</b>	,646 (,04)	<b>1,71 (,542)</b>	<b>2,72 (1,01)</b>	<b>2,85 (1,06)</b>	<b>1,20 (,31)</b>
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	<b>,58 (,776)</b>	,94 (,14)	<b>1,02 (,15)</b>	,670 (,04)	<b>1,63 (,547)</b>	<b>2,04 (,71)</b>	<b>2,15 (,75)</b>	<b>1,06 (,25)</b>
	300	<b>,53 (,795)</b>	,97 (,12)	<b>1,06 (,13)</b>	,670 (,04)	<b>1,66 (,539)</b>	<b>2,26 (,82)</b>	<b>2,36 (,87)</b>	<b>1,09 (,27)</b>
	400	<b>,87 (,688)</b>	,93 (,14)	<b>1,00 (,16)</b>	,648 (,04)	<b>1,72 (,541)</b>	<b>2,51 (,97)</b>	<b>2,63 (1,00)</b>	<b>1,15 (,31)</b>
	500	<b>,53 (,785)</b>	,93 (,16)	<b>1,01 (,18)</b>	,646 (,05)	<b>1,82 (,530)</b>	<b>2,72 (1,01)</b>	<b>2,85 (1,06)</b>	<b>1,20 (,31)</b>
RML	200	<b>,56 (,778)</b>	,95 (,14)	<b>1,03 (,14)</b>	,672 (,04)	<b>1,52 (,568)</b>	<b>2,07 (,73)</b>	<b>2,18 (,77)</b>	<b>1,06 (,26)</b>
	300	<b>,61 (,774)</b>	,97 (,12)	<b>1,05 (,13)</b>	,669 (,04)	<b>1,61 (,546)</b>	<b>2,28 (,84)</b>	<b>2,39 (,89)</b>	<b>1,10 (,28)</b>
	400	<b>,89 (,684)</b>	,93 (,14)	<b>1,00 (,17)</b>	,647 (,04)	<b>1,65 (,546)</b>	<b>2,53 (,97)</b>	<b>2,65 (1,01)</b>	<b>1,16 (,31)</b>
	500	<b>,49 (,799)</b>	,94 (,15)	<b>1,03 (,17)</b>	,650 (,04)	<b>1,79 (,537)</b>	<b>2,73 (1,02)</b>	<b>2,87 (1,07)</b>	<b>1,20 (,32)</b>
RULS	200	<b>,57 (,777)</b>	,94 (,14)	<b>1,02 (,14)</b>	,670 (,04)	<b>1,64 (,548)</b>	<b>2,04 (,71)</b>	<b>2,14 (,75)</b>	<b>1,05 (,25)</b>
	300	<b>,57 (,787)</b>	,97 (,12)	<b>1,06 (,13)</b>	,670 (,04)	<b>1,67 (,539)</b>	<b>2,26 (,82)</b>	<b>2,37 (,87)</b>	<b>1,10 (,27)</b>
	400	<b>,87 (,688)</b>	,93 (,14)	<b>1,00 (,16)</b>	,648 (,04)	<b>1,72 (,539)</b>	<b>2,51 (,97)</b>	<b>2,63 (1,00)</b>	<b>1,15 (,31)</b>
	500	<b>,53 (,785)</b>	,93 (,16)	<b>1,01 (,18)</b>	,646 (,05)	<b>1,84 (,530)</b>	<b>2,72 (1,01)</b>	<b>2,85 (1,06)</b>	<b>1,20 (,31)</b>
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	<b>,61 (,763)</b>	,94 (,13)	<b>1,01 (,13)</b>	,668 (,04)	<b>1,66 (,538)</b>	<b>1,99 (,67)</b>	<b>2,09 (,71)</b>	<b>1,04 (,24)</b>
	300	<b>,59 (,768)</b>	,95 (,12)	<b>1,03 (,13)</b>	,663 (,04)	<b>1,63 (,537)</b>	<b>2,23 (,80)</b>	<b>2,34 (,84)</b>	<b>1,08 (,26)</b>
	400	<b>,66 (,756)</b>	,94 (,14)	<b>1,02 (,15)</b>	,653 (,04)	<b>1,76 (,537)</b>	<b>2,48 (,98)</b>	<b>2,60 (1,02)</b>	<b>1,14 (,31)</b>
	500	<b>,58 (,769)</b>	,94 (,14)	<b>1,02 (,16)</b>	,648 (,04)	<b>1,84 (,525)</b>	<b>2,71 (1,03)</b>	<b>2,84 (1,08)</b>	<b>1,20 (,32)</b>
RML	200	<b>,59 (,774)</b>	,92 (,13)	<b>1,00 (,13)</b>	,664 (,04)	<b>1,58 (,549)</b>	<b>2,00 (,69)</b>	<b>2,09 (,73)</b>	<b>1,04 (,24)</b>
	300	<b>,69 (,744)</b>	,95 (,12)	<b>1,03 (,14)</b>	,662 (,04)	<b>1,60 (,541)</b>	<b>2,25 (,82)</b>	<b>2,35 (,86)</b>	<b>1,09 (,27)</b>
	400	<b>,69 (,743)</b>	,95 (,14)	<b>1,02 (,15)</b>	,654 (,04)	<b>1,68 (,543)</b>	<b>2,50 (,99)</b>	<b>2,62 (1,03)</b>	<b>1,15 (,31)</b>
	500	<b>,56 (,775)</b>	,94 (,14)	<b>1,02 (,16)</b>	,648 (,04)	<b>1,83 (,526)</b>	<b>2,72 (1,03)</b>	<b>2,84 (1,08)</b>	<b>1,20 (,32)</b>
RULS	200	<b>,61 (,763)</b>	,94 (,13)	<b>1,01 (,14)</b>	,668 (,04)	<b>1,65 (,536)</b>	<b>1,98 (,67)</b>	<b>2,08 (,71)</b>	<b>1,03 (,24)</b>
	300	<b>,65 (,757)</b>	,95 (,12)	<b>1,03 (,13)</b>	,662 (,04)	<b>1,65 (,534)</b>	<b>2,24 (,81)</b>	<b>2,34 (,85)</b>	<b>1,09 (,27)</b>
	400	<b>,67 (,753)</b>	,94 (,14)	<b>1,02 (,15)</b>	,652 (,04)	<b>1,75 (,536)</b>	<b>2,48 (,98)</b>	<b>2,59 (1,01)</b>	<b>1,14 (,31)</b>
	500	<b>,58 (,769)</b>	,94 (,14)	<b>1,02 (,16)</b>	,648 (,04)	<b>1,87 (,523)</b>	<b>2,71 (1,03)</b>	<b>2,84 (1,08)</b>	<b>1,20 (,32)</b>

 $\chi^2_0 (p-v)$  - Media (nivel crítico).ECVI<sub>r</sub>, AIC<sub>r</sub>, CAIC<sub>r</sub> - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0; p \geq 0,05$ ) y las celdas en las que el valor ECVI, AIC o CAIC del modelo nulo es mayor que el del modelo evaluado (razón > 1).

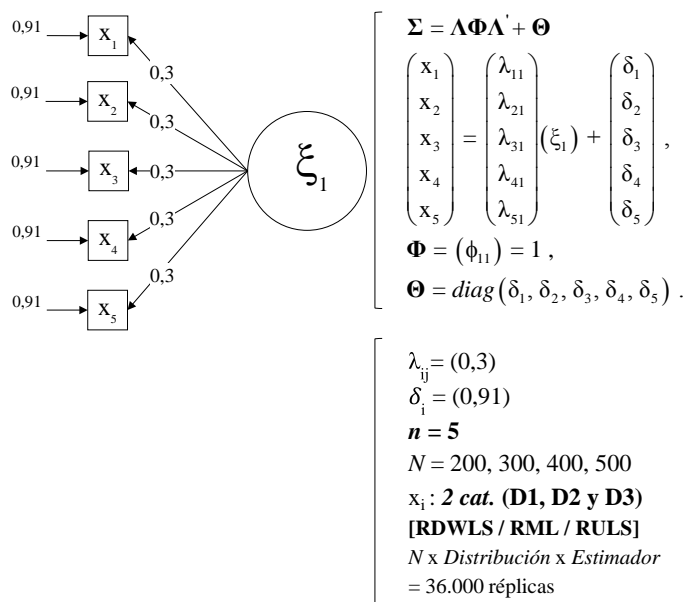
**Tabla 10.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).

Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.00)	,02 (.01)	,94 (.04)	1,84 (**)	,83 (.12)	,79 (.40)	,02 (.03)	,04 (.01)	,94 (.04)	1,11 (.25)	,83 (.14)	,98 (.03)
	300	,00 (.00)	,02 (.00)	,96 (.04)	2,15 (9,24)	,87 (.15)	,91 (.29)	,01 (.02)	,03 (.01)	,95 (.04)	1,09 (.21)	,85 (.13)	,99 (.03)
	400	,00 (.00)	,02 (.00)	,94 (.04)	1,99 (**)	,82 (.15)	,73 (.45)	,01 (.02)	,03 (.01)	,95 (.04)	1,07 (.20)	,86 (.12)	,99 (.02)
	500	,00 (.00)	,01 (.00)	,95 (.03)	2,03 (4,04)	,86 (.09)	,79 (.41)	,01 (.02)	,02 (.01)	,96 (.03)	1,07 (.18)	,87 (.11)	,99 (.02)
RML	200	,00 (.00)	,02 (.01)	,95 (.04)	1,90 (**)	,84 (.12)	,78 (.41)	,01 (.03)	,04 (.01)	,95 (.04)	1,13 (.24)	,85 (.13)	,99 (.02)
	300	,00 (.00)	,02 (.00)	,96 (.05)	2,15 (9,37)	,87 (.15)	,91 (.29)	,01 (.02)	,03 (.01)	,95 (.04)	1,10 (.20)	,86 (.12)	,99 (.02)
	400	,00 (.00)	,02 (.00)	,94 (.05)	2,03 (**)	,83 (.15)	,75 (.44)	,01 (.02)	,03 (.01)	,96 (.03)	1,08 (.19)	,87 (.11)	,99 (.02)
	500	,00 (.00)	,01 (.00)	,95 (.03)	2,01 (4,14)	,86 (.09)	,78 (.42)	,01 (.02)	,02 (.01)	,96 (.03)	1,07 (.18)	,88 (.11)	,99 (.02)
RULS	200	,00 (.00)	,02 (.01)	,94 (.04)	1,84 (**)	,83 (.12)	,79 (.40)	,02 (.03)	,04 (.01)	,94 (.04)	1,11 (.25)	,83 (.14)	,98 (.03)
	300	,00 (.00)	,02 (.00)	,96 (.04)	2,15 (9,24)	,87 (.15)	,91 (.29)	,01 (.02)	,03 (.01)	,95 (.04)	1,09 (.21)	,85 (.13)	,99 (.03)
	400	,00 (.00)	,02 (.00)	,94 (.04)	1,99 (**)	,82 (.15)	,73 (.45)	,01 (.02)	,03 (.01)	,95 (.03)	1,07 (.19)	,86 (.12)	,99 (.02)
	500	,00 (.00)	,01 (.00)	,95 (.03)	2,03 (4,04)	,86 (.09)	,79 (.41)	,01 (.02)	,02 (.01)	,96 (.03)	1,07 (.18)	,87 (.11)	,99 (.02)
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.01)	,03 (.01)	,94 (.05)	1,84 (**)	,81 (.17)	,80 (.39)	,02 (.03)	,04 (.01)	,94 (.05)	1,10 (.25)	,83 (.16)	,98 (.04)
	300	,00 (.01)	,02 (.01)	,94 (.06)	1,95 (**)	,83 (.18)	,92 (.26)	,01 (.02)	,03 (.01)	,95 (.05)	1,09 (.23)	,84 (.15)	,98 (.04)
	400	,00 (.01)	,02 (.01)	,89 (.09)	1,95 (3,24)	,68 (.29)	,85 (.34)	,01 (.02)	,03 (.01)	,95 (.04)	1,07 (.21)	,86 (.13)	,99 (.03)
	500	,00 (.00)	,02 (.01)	,93 (.07)	1,98 (4,48)	,79 (.21)	,77 (.42)	,01 (.02)	,03 (.01)	,95 (.04)	1,06 (.20)	,86 (.14)	,98 (.03)
RML	200	,00 (.01)	,03 (.01)	,94 (.06)	1,84 (**)	,81 (.19)	,81 (.39)	,01 (.03)	,04 (.02)	,95 (.05)	1,11 (.25)	,84 (.15)	,98 (.03)
	300	,00 (.01)	,02 (.01)	,93 (.07)	1,93 (8,33)	,80 (.23)	,91 (.27)	,01 (.02)	,03 (.01)	,95 (.04)	1,09 (.22)	,84 (.14)	,99 (.03)
	400	,00 (.01)	,02 (.01)	,89 (.10)	1,93 (2,99)	,66 (.31)	,82 (.36)	,01 (.02)	,03 (.01)	,96 (.04)	1,07 (.19)	,87 (.12)	,99 (.02)
	500	,00 (.00)	,02 (.01)	,94 (.05)	2,00 (4,59)	,82 (.16)	,81 (.40)	,01 (.02)	,03 (.01)	,96 (.04)	1,07 (.21)	,87 (.14)	,98 (.04)
RULS	200	,00 (.01)	,03 (.01)	,94 (.05)	1,84 (**)	,81 (.17)	,80 (.39)	,02 (.03)	,04 (.02)	,94 (.05)	1,10 (.25)	,83 (.16)	,98 (.04)
	300	,00 (.01)	,02 (.01)	,94 (.06)	1,95 (**)	,83 (.20)	,92 (.26)	,01 (.02)	,03 (.01)	,95 (.05)	1,09 (.23)	,84 (.15)	,98 (.04)
	400	,00 (.01)	,02 (.01)	,89 (.09)	1,95 (3,24)	,68 (.29)	,85 (.34)	,01 (.02)	,03 (.01)	,95 (.04)	1,07 (.21)	,86 (.13)	,99 (.03)
	500	,00 (.00)	,02 (.01)	,93 (.07)	1,98 (4,48)	,79 (.21)	,77 (.42)	,01 (.02)	,03 (.01)	,95 (.04)	1,06 (.21)	,86 (.15)	,98 (.04)
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.01)	,03 (.01)	,93 (.06)	1,87 (7,60)	,80 (.18)	,80 (.39)	,02 (.03)	,04 (.01)	,94 (.05)	1,11 (.25)	,82 (.15)	,98 (.03)
	300	,00 (.00)	,02 (.01)	,93 (.06)	1,95 (8,53)	,80 (.18)	,90 (.29)	,01 (.02)	,03 (.01)	,95 (.04)	1,09 (.22)	,84 (.15)	,99 (.03)
	400	,00 (.01)	,02 (.01)	,92 (.08)	2,03 (**)	,77 (.27)	,85 (.34)	,01 (.02)	,03 (.01)	,95 (.04)	1,07 (.22)	,85 (.14)	,98 (.04)
	500	,00 (.00)	,02 (.01)	,93 (.06)	2,01 (3,16)	,79 (.20)	,79 (.41)	,01 (.02)	,03 (.01)	,95 (.04)	1,06 (.20)	,86 (.14)	,98 (.04)
RML	200	,00 (.01)	,03 (.01)	,94 (.06)	1,89 (8,45)	,81 (.18)	,78 (.41)	,01 (.03)	,04 (.02)	,94 (.04)	1,12 (.25)	,83 (.15)	,98 (.03)
	300	,00 (.01)	,02 (.01)	,92 (.07)	1,93 (9,06)	,76 (.23)	,89 (.30)	,01 (.02)	,03 (.01)	,95 (.04)	1,09 (.21)	,84 (.14)	,99 (.03)
	400	,00 (.00)	,02 (.01)	,92 (.08)	2,01 (**)	,76 (.27)	,86 (.34)	,01 (.02)	,03 (.01)	,95 (.04)	1,07 (.21)	,86 (.13)	,99 (.03)
	500	,00 (.00)	,02 (.01)	,93 (.06)	2,01 (3,20)	,80 (.19)	,79 (.41)	,01 (.02)	,03 (.01)	,95 (.04)	1,06 (.20)	,86 (.15)	,98 (.04)
RULS	200	,00 (.01)	,03 (.01)	,93 (.06)	1,87 (7,64)	,80 (.18)	,80 (.39)	,02 (.03)	,04 (.01)	,94 (.05)	1,11 (.25)	,82 (.15)	,98 (.03)
	300	,00 (.01)	,02 (.01)	,93 (.06)	1,95 (8,68)	,78 (.20)	,90 (.29)	,01 (.02)	,03 (.01)	,95 (.05)	1,09 (.22)	,84 (.15)	,98 (.03)
	400	,00 (.01)	,02 (.01)	,92 (.08)	2,03 (**)	,76 (.27)	,85 (.35)	,01 (.02)	,03 (.01)	,95 (.04)	1,07 (.22)	,85 (.14)	,98 (.04)
	500	,00 (.00)	,02 (.01)	,93 (.06)	2,01 (3,16)	,79 (.20)	,79 (.41)	,01 (.02)	,03 (.01)	,95 (.05)	1,06 (.21)	,86 (.15)	,98 (.04)

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

Ficha 11. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3$ ,  $n = 5$ )**Cuadro 11.1.** Path diagram, notación matricial y condiciones simuladas**Tabla 11.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución x  $N$  x Estimador.

Distribución	$N$	IM ( $\lambda_{ij} = 0,3; n = 5$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,3; n = 5$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,3; n = 5$ )		
		RDWLS	RML	RULS	RDWLS	RML	RULS	RDWLS	RML	RULS
D1	200	23,9%	35,9%	24,5%	4,8%	3,3%	4,8%	71,3%	60,8%	70,7%
	300	13,0%	19,8%	13,2%	3,2%	2,8%	3,2%	83,8%	77,4%	83,6%
	400	8,4%	13,9%	8,7%	1,1%	1,0%	1,1%	90,5%	85,1%	90,2%
	500	4,4%	8,0%	4,4%	0,7%	0,7%	0,7%	94,9%	91,3%	94,9%
D2	200	26,2%	37,3%	26,9%	4,6%	3,3%	4,4%	69,2%	59,4%	68,7%
	300	16,9%	24,8%	17,1%	3,0%	2,5%	3,0%	80,1%	72,7%	79,9%
	400	9,2%	15,4%	9,6%	1,1%	1,0%	1,0%	89,7%	83,6%	89,4%
	500	5,5%	10,0%	5,6%	0,7%	0,7%	0,7%	93,8%	89,3%	93,7%
D3	200	34,9%	47,3%	35,6%	4,9%	3,7%	5,0%	60,2%	49,0%	59,4%
	300	21,1%	32,5%	22,3%	3,5%	2,8%	3,4%	75,4%	64,7%	74,3%
	400	15,9%	23,2%	16,2%	1,1%	1,1%	1,1%	83,0%	75,7%	82,7%
	500	11,8%	17,8%	12,5%	0,7%	0,6%	0,7%	87,5%	81,6%	86,8%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 11.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ). Distribución x N x Estimador (Media (D.T.))

D1	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	76,1%	4,8%	,61 (.41)	,25 (.14)	,21 (.12)	,82 (.46)	71,3%	,79 (.32)	,21 (.11)	,18 (.10)	,72 (.36)
	300	87,0%	3,2%	,75 (.19)	,20 (.09)	,17 (.08)	,66 (.29)	83,8%	,83 (.29)	<b>,18 (.09)</b>	,15 (.08)	,60 (.31)
	400	91,6%	1,1%	,69 (.42)	,20 (.10)	,18 (.09)	,68 (.34)	90,5%	,87 (.23)	<b>,16 (.08)</b>	,13 (.07)	,52 (.27)
	500	95,6%	0,7%	,76 (.14)	,20 (.07)	,17 (.07)	,66 (.22)	94,9%	,90 (.15)	<b>,14 (.06)</b>	,11 (.05)	,45 (.20)
RML	200	64,1%	3,3%	,68 (.33)	,22 (.12)	,19 (.10)	,74 (.39)	60,8%	,79 (.31)	,22 (.10)	,18 (.09)	,73 (.34)
	300	80,2%	2,8%	,76 (.19)	,20 (.09)	,17 (.08)	,66 (.30)	77,4%	,84 (.26)	<b>,19 (.09)</b>	,15 (.08)	,62 (.29)
	400	86,1%	1,0%	,69 (.43)	,20 (.11)	,18 (.10)	,68 (.36)	85,1%	,87 (.21)	<b>,16 (.08)</b>	,13 (.07)	,53 (.26)
	500	92,0%	0,7%	,75 (.15)	,21 (.08)	,18 (.08)	,69 (.26)	91,3%	,90 (.13)	<b>,14 (.06)</b>	,12 (.05)	,47 (.20)
RULS	200	75,5%	4,8%	,59 (.44)	,25 (.15)	,22 (.13)	,85 (.49)	70,7%	,79 (.32)	,21 (.11)	,18 (.10)	,72 (.36)
	300	86,8%	3,2%	,75 (.19)	,20 (.09)	,17 (.08)	,67 (.29)	83,6%	,84 (.28)	<b>,18 (.09)</b>	,15 (.08)	,60 (.30)
	400	91,3%	1,1%	,69 (.42)	,20 (.10)	,18 (.09)	,68 (.34)	90,2%	,87 (.23)	<b>,16 (.08)</b>	,13 (.07)	,52 (.27)
	500	95,6%	0,7%	,76 (.14)	,20 (.07)	,17 (.07)	,66 (.22)	94,9%	,90 (.15)	<b>,14 (.06)</b>	,11 (.05)	,45 (.20)
D2	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	73,8%	4,6%	,45 (.57)	,30 (.16)	,26 (.14)	1,00 (.52)	69,2%	,79 (.31)	,22 (.10)	,18 (.09)	,72 (.34)
	300	83,1%	3,0%	,70 (.42)	,21 (.13)	,18 (.11)	,71 (.43)	80,1%	,85 (.21)	<b>,18 (.08)</b>	,15 (.07)	,59 (.27)
	400	90,8%	1,1%	,69 (.45)	,22 (.14)	,19 (.12)	,73 (.46)	89,7%	,87 (.22)	<b>,16 (.08)</b>	,13 (.07)	,53 (.26)
	500	94,5%	0,7%	,86 (.08)	<b>,15 (.04)</b>	,13 (.04)	,51 (.14)	93,8%	,90 (.15)	<b>,14 (.06)</b>	,12 (.06)	,46 (.21)
RML	200	62,7%	3,3%	,40 (.59)	,31 (.16)	,27 (.14)	1,03 (.53)	59,4%	,80 (.29)	,22 (.10)	,18 (.09)	,73 (.32)
	300	75,2%	2,5%	,73 (.37)	,20 (.12)	,17 (.10)	,67 (.40)	72,7%	,85 (.22)	<b>,18 (.08)</b>	,15 (.07)	,60 (.27)
	400	84,6%	1,0%	,66 (.45)	,24 (.15)	,20 (.13)	,80 (.50)	83,6%	,87 (.20)	<b>,16 (.07)</b>	,13 (.07)	,54 (.25)
	500	90,0%	0,7%	,86 (.07)	<b>,16 (.04)</b>	,13 (.04)	,52 (.14)	89,3%	,90 (.13)	<b>,14 (.06)</b>	,12 (.05)	,47 (.21)
RULS	200	73,1%	4,4%	,47 (.55)	,29 (.15)	,25 (.13)	,98 (.50)	68,7%	,80 (.30)	,22 (.10)	,18 (.09)	,72 (.33)
	300	82,9%	3,0%	,70 (.42)	,21 (.13)	,18 (.11)	,71 (.43)	79,9%	,85 (.24)	<b>,18 (.08)</b>	,15 (.07)	,60 (.28)
	400	90,4%	1,0%	,66 (.47)	,23 (.14)	,20 (.13)	,77 (.47)	89,4%	,87 (.21)	<b>,16 (.08)</b>	,13 (.07)	,53 (.25)
	500	94,4%	0,7%	,86 (.08)	<b>,15 (.04)</b>	,13 (.04)	,51 (.14)	93,7%	,90 (.14)	<b>,14 (.06)</b>	,11 (.05)	,46 (.21)
D3	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 5)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	65,1%	4,9%	,62 (.43)	,28 (.13)	,23 (.11)	,93 (.43)	60,2%	,70 (.43)	,26 (.14)	,21 (.12)	,85 (.45)
	300	78,9%	3,5%	,72 (.39)	,23 (.13)	,18 (.11)	,75 (.42)	75,4%	,77 (.38)	,21 (.12)	,18 (.11)	,71 (.39)
	400	84,1%	1,1%	,81 (.20)	<b>,19 (.08)</b>	,16 (.07)	,64 (.27)	83,0%	,83 (.29)	<b>,18 (.09)</b>	,15 (.09)	,60 (.31)
	500	88,2%	0,7%	,84 (.20)	<b>,16 (.10)</b>	,14 (.09)	,53 (.34)	87,5%	,87 (.21)	<b>,16 (.08)</b>	,13 (.07)	,53 (.26)
RML	200	52,7%	3,7%	,57 (.47)	,30 (.13)	,25 (.12)	,99 (.43)	49,0%	,72 (.41)	,25 (.13)	,21 (.11)	,84 (.43)
	300	67,5%	2,8%	,75 (.34)	,21 (.10)	,17 (.09)	,71 (.33)	64,7%	,78 (.35)	,21 (.11)	,18 (.10)	,72 (.37)
	400	76,8%	1,1%	,79 (.19)	,20 (.09)	,17 (.07)	,68 (.29)	75,7%	,84 (.26)	<b>,18 (.09)</b>	,15 (.08)	,61 (.30)
	500	82,2%	0,6%	,86 (.20)	<b>,14 (.09)</b>	,12 (.08)	,45 (.29)	81,6%	,87 (.19)	<b>,16 (.08)</b>	,14 (.07)	,54 (.26)
RULS	200	64,4%	5,0%	,58 (.47)	,29 (.13)	,24 (.12)	,96 (.45)	59,4%	,71 (.42)	,25 (.13)	,21 (.12)	,84 (.43)
	300	77,7%	3,4%	,76 (.32)	,21 (.10)	,17 (.09)	,71 (.34)	74,3%	,77 (.38)	,22 (.12)	,18 (.11)	,72 (.39)
	400	83,8%	1,1%	,80 (.20)	<b>,19 (.08)</b>	,16 (.07)	,65 (.27)	82,7%	,84 (.27)	<b>,18 (.09)</b>	,15 (.08)	,59 (.30)
	500	87,5%	0,7%	,83 (.20)	<b>,16 (.10)</b>	,14 (.09)	,53 (.34)	86,8%	,87 (.20)	<b>,16 (.08)</b>	,13 (.07)	,53 (.26)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene H<sub>0</sub> del Modelo de Independencia; T1 - % soluciones en las que se rechaza H<sub>0</sub> del Modelo de Independencia.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones (C<sub>j</sub> ≥ 0,92, RMSD<sub>j</sub> < 0,2, ARB<sub>j</sub> ≤ 0,10 y AMSE<sub>j</sub> ≤ 0,10).

**Tabla 11.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	1,66 (,875)	,98 (,11)	1,13 (,12)	,710 (,04)	4,59 (,538)	2,11 (,60)	2,24 (,63)	1,13 (,23)
	300	1,65 (,873)	1,03 (,09)	1,20 (,11)	,720 (,03)	4,57 (,538)	2,39 (,74)	2,53 (,78)	1,19 (,26)
	400	1,64 (,879)	1,01 (,10)	1,17 (,12)	,703 (,03)	4,66 (,527)	2,64 (,84)	2,79 (,88)	1,25 (,29)
	500	1,40 (,915)	,99 (,08)	1,16 (,08)	,692 (,02)	4,79 (,513)	2,90 (,92)	3,06 (,98)	1,32 (,31)
RML	200	1,46 (,899)	,96 (,11)	1,12 (,13)	,706 (,04)	4,33 (,562)	2,14 (,61)	2,28 (,63)	1,14 (,23)
	300	1,46 (,898)	1,04 (,09)	1,21 (,10)	,723 (,03)	4,42 (,554)	2,41 (,75)	2,56 (,79)	1,20 (,27)
	400	1,65 (,877)	1,03 (,08)	1,20 (,10)	,711 (,02)	4,54 (,537)	2,67 (,85)	2,82 (,89)	1,26 (,29)
	500	1,39 (,915)	,99 (,08)	1,16 (,08)	,692 (,02)	4,66 (,523)	2,92 (,92)	3,09 (,98)	1,33 (,31)
RULS	200	1,66 (,875)	,98 (,11)	1,13 (,12)	,710 (,04)	4,57 (,540)	2,11 (,60)	2,24 (,63)	1,13 (,23)
	300	1,65 (,873)	1,03 (,09)	1,20 (,11)	,720 (,03)	4,56 (,538)	2,39 (,74)	2,53 (,78)	1,19 (,26)
	400	1,64 (,879)	1,01 (,10)	1,17 (,12)	,703 (,03)	4,64 (,527)	2,64 (,84)	2,79 (,88)	1,25 (,29)
	500	1,40 (,915)	,99 (,08)	1,16 (,08)	,692 (,02)	4,80 (,512)	2,90 (,92)	3,06 (,98)	1,32 (,31)
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	1,78 (,860)	,99 (,12)	1,14 (,13)	,713 (,04)	4,47 (,549)	2,08 (,60)	2,20 (,62)	1,11 (,23)
	300	1,70 (,867)	1,02 (,11)	1,18 (,13)	,715 (,04)	4,49 (,544)	2,39 (,75)	2,53 (,79)	1,19 (,27)
	400	2,05 (,826)	1,03 (,10)	1,17 (,12)	,706 (,03)	4,59 (,531)	2,62 (,85)	2,77 (,89)	1,25 (,29)
	500	1,90 (,846)	1,02 (,08)	1,16 (,08)	,696 (,02)	4,77 (,516)	2,91 (,92)	3,07 (,98)	1,32 (,31)
RML	200	1,66 (,873)	,98 (,12)	1,13 (,13)	,712 (,04)	4,37 (,561)	2,10 (,62)	2,23 (,64)	1,12 (,23)
	300	1,66 (,870)	1,02 (,12)	1,18 (,14)	,713 (,04)	4,41 (,553)	2,41 (,76)	2,56 (,80)	1,20 (,27)
	400	2,12 (,820)	1,02 (,10)	1,16 (,12)	,702 (,03)	4,61 (,531)	2,65 (,85)	2,80 (,89)	1,25 (,29)
	500	1,89 (,846)	1,02 (,08)	1,16 (,08)	,696 (,02)	4,70 (,521)	2,91 (,93)	3,08 (,99)	1,32 (,31)
RULS	200	1,76 (,861)	,99 (,12)	1,14 (,13)	,715 (,04)	4,49 (,548)	2,08 (,61)	2,20 (,62)	1,11 (,23)
	300	1,78 (,857)	1,02 (,11)	1,18 (,13)	,714 (,04)	4,52 (,543)	2,39 (,75)	2,53 (,79)	1,19 (,27)
	400	1,96 (,839)	1,04 (,10)	1,19 (,12)	,710 (,03)	4,61 (,530)	2,63 (,85)	2,78 (,89)	1,25 (,29)
	500	1,90 (,846)	1,02 (,08)	1,16 (,08)	,696 (,02)	4,79 (,515)	2,91 (,93)	3,07 (,98)	1,32 (,31)
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$			
		$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>	$\chi^2_0 (p-v)$	ECVI <sub>r</sub>	AIC <sub>r</sub>	CAIC <sub>r</sub>
RDWLS	200	1,83 (,853)	,99 (,11)	1,13 (,12)	,713 (,04)	4,68 (,523)	2,11 (,60)	2,23 (,63)	1,12 (,23)
	300	1,72 (,867)	1,04 (,07)	1,20 (,09)	,720 (,02)	4,62 (,531)	2,37 (,74)	2,51 (,77)	1,19 (,26)
	400	1,85 (,853)	1,01 (,11)	1,16 (,12)	,701 (,03)	4,70 (,523)	2,63 (,86)	2,77 (,91)	1,25 (,30)
	500	1,95 (,840)	1,05 (,08)	1,19 (,09)	,704 (,02)	4,76 (,514)	2,91 (,93)	3,07 (,99)	1,32 (,31)
RML	200	1,92 (,840)	,99 (,12)	1,14 (,13)	,715 (,04)	4,61 (,529)	2,13 (,61)	2,25 (,63)	1,13 (,23)
	300	1,61 (,880)	1,04 (,07)	1,21 (,09)	,722 (,02)	4,67 (,526)	2,40 (,74)	2,54 (,78)	1,20 (,26)
	400	1,81 (,859)	1,01 (,11)	1,16 (,12)	,701 (,03)	4,68 (,524)	2,64 (,86)	2,79 (,91)	1,25 (,30)
	500	1,93 (,840)	1,03 (,08)	1,17 (,08)	,700 (,02)	4,74 (,517)	2,93 (,94)	3,09 (1,00)	1,33 (,31)
RULS	200	1,81 (,856)	,98 (,11)	1,13 (,12)	,711 (,04)	4,68 (,521)	2,11 (,60)	2,23 (,63)	1,13 (,23)
	300	1,80 (,856)	1,04 (,07)	1,19 (,09)	,719 (,02)	4,65 (,529)	2,37 (,74)	2,51 (,78)	1,19 (,27)
	400	1,85 (,854)	1,01 (,11)	1,16 (,12)	,701 (,03)	4,71 (,522)	2,63 (,86)	2,77 (,91)	1,25 (,30)
	500	1,95 (,840)	1,05 (,08)	1,19 (,09)	,704 (,02)	4,76 (,515)	2,91 (,93)	3,07 (,99)	1,32 (,31)

 $\chi^2_0 (p-v)$  - Media (nivel crítico).ECVI<sub>r</sub>, AIC<sub>r</sub>, CAIC<sub>r</sub> - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0; p \geq 0,05$ ) y las celdas en las que el valor ECVI, AIC o CAIC del modelo nulo es mayor que el del modelo evaluado (razón > 1).

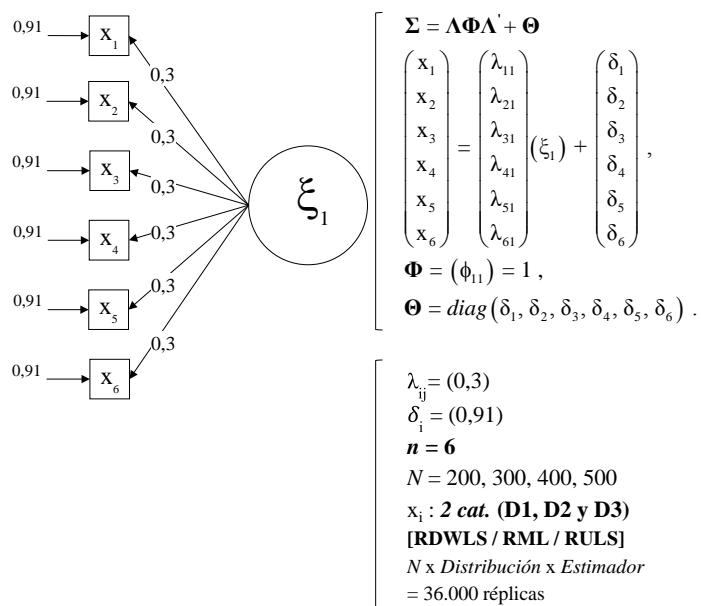
**Tabla 11.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).

Distribución  $x \times N$  x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (,00)	,03 (,01)	,89 (,05)	2,14 (**)	,78 (,10)	,88 (,33)	,01 (,02)	,05 (,01)	,90 (,05)	1,07 (,19)	,80 (,10)	,98 (,03)
	300	,00 (,00)	,03 (,00)	,90 (,05)	2,00 (1,10)	,80 (,11)	,97 (,17)	,01 (,02)	,04 (,01)	,91 (,04)	1,05 (,17)	,82 (,10)	,98 (,03)
	400	,00 (,00)	,02 (,00)	,90 (,04)	2,10 (**)	,79 (,10)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,15)	,84 (,09)	,99 (,02)
	500	,00 (,00)	,02 (,00)	,90 (,04)	2,19 (1,44)	,81 (,08)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,03 (,13)	,85 (,09)	,98 (,02)
RML	200	,00 (,00)	,03 (,01)	,90 (,05)	2,26 (**)	,80 (,10)	,88 (,33)	,01 (,02)	,05 (,01)	,91 (,04)	1,08 (,18)	,81 (,10)	,99 (,03)
	300	,00 (,00)	,03 (,00)	,91 (,04)	2,00 (1,14)	,83 (,09)	,96 (,18)	,01 (,02)	,04 (,01)	,91 (,04)	1,06 (,17)	,83 (,09)	,99 (,02)
	400	,00 (,00)	,02 (,00)	,90 (,05)	2,08 (1,94)	,80 (,10)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,15)	,84 (,08)	,99 (,02)
	500	,00 (,00)	,02 (,00)	,90 (,04)	2,19 (1,44)	,81 (,08)	1,0 (,00)	,01 (,02)	,04 (,01)	,93 (,04)	1,04 (,12)	,85 (,08)	,99 (,02)
RULS	200	,00 (,00)	,03 (,01)	,89 (,05)	2,14 (**)	,78 (,10)	,88 (,33)	,01 (,02)	,05 (,01)	,90 (,05)	1,07 (,19)	,80 (,10)	,98 (,03)
	300	,00 (,00)	,03 (,00)	,90 (,05)	2,00 (1,10)	,80 (,11)	,97 (,17)	,01 (,02)	,04 (,01)	,91 (,04)	1,05 (,17)	,82 (,10)	,98 (,03)
	400	,00 (,00)	,02 (,00)	,90 (,04)	2,10 (**)	,79 (,10)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,15)	,84 (,09)	,99 (,02)
	500	,00 (,00)	,02 (,00)	,90 (,04)	2,19 (1,44)	,81 (,08)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,03 (,13)	,85 (,09)	,98 (,02)
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (,00)	,04 (,01)	,88 (,05)	2,04 (7,20)	,77 (,12)	,87 (,34)	,01 (,02)	,05 (,01)	,90 (,05)	1,08 (,20)	,80 (,10)	,98 (,03)
	300	,00 (,00)	,03 (,00)	,89 (,05)	1,99 (1,37)	,79 (,12)	,93 (,25)	,01 (,02)	,04 (,01)	,91 (,04)	1,05 (,17)	,82 (,09)	,99 (,03)
	400	,00 (,00)	,03 (,00)	,87 (,06)	2,03 (**)	,74 (,13)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,16)	,84 (,09)	,99 (,03)
	500	,00 (,00)	,02 (,00)	,88 (,08)	2,09 (1,52)	,75 (,16)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,03 (,13)	,85 (,09)	,98 (,02)
RML	200	,00 (,00)	,04 (,01)	,89 (,06)	2,09 (6,36)	,78 (,12)	,85 (,36)	,01 (,02)	,05 (,01)	,90 (,05)	1,09 (,21)	,80 (,11)	,98 (,04)
	300	,00 (,00)	,03 (,01)	,89 (,06)	1,99 (1,48)	,79 (,13)	,92 (,27)	,01 (,02)	,04 (,01)	,91 (,04)	1,06 (,17)	,83 (,10)	,99 (,03)
	400	,00 (,00)	,03 (,00)	,86 (,05)	2,04 (**)	,73 (,11)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,16)	,84 (,10)	,98 (,03)
	500	,00 (,00)	,02 (,00)	,88 (,08)	2,09 (1,51)	,75 (,16)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,13)	,85 (,09)	,99 (,03)
RULS	200	,00 (,00)	,04 (,01)	,88 (,06)	2,06 (5,52)	,77 (,12)	,86 (,34)	,01 (,02)	,05 (,01)	,90 (,05)	1,08 (,20)	,80 (,10)	,98 (,03)
	300	,00 (,00)	,03 (,01)	,89 (,06)	1,98 (1,35)	,78 (,13)	,93 (,25)	,01 (,02)	,04 (,01)	,91 (,04)	1,05 (,17)	,82 (,10)	,98 (,03)
	400	,00 (,00)	,03 (,00)	,88 (,05)	2,04 (**)	,76 (,11)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,16)	,84 (,09)	,99 (,03)
	500	,00 (,00)	,02 (,00)	,88 (,08)	2,09 (1,52)	,75 (,16)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,03 (,13)	,85 (,09)	,98 (,03)
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 5)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 5)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (,00)	,04 (,01)	,88 (,06)	2,02 (**)	,76 (,12)	,88 (,33)	,01 (,02)	,05 (,01)	,90 (,05)	1,06 (,19)	,79 (,10)	,98 (,03)
	300	,00 (,00)	,03 (,00)	,90 (,06)	2,08 (,85)	,79 (,13)	1,0 (,02)	,01 (,02)	,04 (,01)	,91 (,04)	1,05 (,18)	,82 (,10)	,98 (,03)
	400	,00 (,00)	,03 (,00)	,88 (,06)	2,03 (**)	,76 (,12)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,16)	,83 (,09)	,98 (,03)
	500	,00 (,00)	,02 (,00)	,88 (,07)	2,03 (1,54)	,76 (,16)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,03 (,13)	,85 (,09)	,98 (,03)
RML	200	,00 (,01)	,04 (,01)	,88 (,07)	1,99 (**)	,75 (,16)	,86 (,34)	,01 (,02)	,06 (,01)	,90 (,05)	1,07 (,19)	,80 (,10)	,98 (,03)
	300	,00 (,00)	,03 (,01)	,90 (,06)	2,08 (,79)	,80 (,14)	1,0 (,02)	,01 (,02)	,05 (,01)	,91 (,04)	1,05 (,17)	,82 (,10)	,98 (,03)
	400	,00 (,00)	,03 (,00)	,88 (,05)	2,05 (**)	,76 (,11)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,16)	,83 (,10)	,98 (,03)
	500	,00 (,00)	,02 (,01)	,88 (,08)	2,06 (1,66)	,76 (,17)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,13)	,85 (,09)	,98 (,03)
RULS	200	,00 (,00)	,04 (,01)	,88 (,05)	2,02 (**)	,77 (,12)	,86 (,35)	,01 (,02)	,05 (,01)	,90 (,05)	1,06 (,19)	,79 (,10)	,98 (,03)
	300	,00 (,00)	,03 (,01)	,89 (,07)	2,04 (,86)	,78 (,14)	1,0 (,02)	,01 (,02)	,04 (,01)	,91 (,05)	1,05 (,18)	,82 (,10)	,98 (,03)
	400	,00 (,00)	,03 (,00)	,88 (,06)	2,03 (**)	,76 (,12)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,04 (,16)	,83 (,09)	,98 (,03)
	500	,00 (,00)	,02 (,00)	,88 (,07)	2,03 (1,54)	,76 (,16)	1,0 (,00)	,01 (,02)	,04 (,01)	,92 (,04)	1,03 (,13)	,85 (,09)	,98 (,03)

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

Ficha 12. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,3$ ,  $n = 6$ )**Cuadro 12.1.** Path diagram, notación matricial y condiciones simuladas**Tabla 12.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución x  $N$  x Estimador.

Distribución	$N$	IM ( $\lambda_{ij} = 0,3; n = 6$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,3; n = 6$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,3; n = 6$ )		
		RDWLS	RML	RULS	RDWLS	RML	RULS	RDWLS	RML	RULS
D1	200	14,4%	29,2%	15,1%	1,4%	1,0%	1,5%	84,2%	69,8%	83,4%
	300	6,7%	14,2%	6,8%	0,6%	0,6%	0,6%	92,7%	85,2%	92,6%
	400	3,9%	7,4%	4,1%	0,0%	0,0%	0,0%	96,1%	92,6%	95,9%
	500	1,3%	3,3%	1,3%	0,0%	0,0%	0,0%	98,7%	96,7%	98,7%
D2	200	15,2%	27,4%	15,1%	1,6%	1,3%	1,6%	83,2%	71,3%	83,3%
	300	7,4%	16,6%	7,7%	0,6%	0,5%	0,6%	92,0%	82,9%	91,7%
	400	4,3%	9,1%	4,4%	0,1%	0,1%	0,1%	95,6%	90,8%	95,5%
	500	2,3%	4,3%	2,6%	0,0%	0,0%	0,0%	97,7%	95,7%	97,4%
D3	200	20,6%	40,1%	22,5%	1,8%	1,4%	1,8%	77,6%	58,5%	75,7%
	300	13,7%	27,1%	15,4%	0,8%	0,8%	0,8%	85,5%	72,1%	83,8%
	400	6,8%	17,6%	7,9%	0,1%	0,1%	0,1%	93,1%	82,3%	92,0%
	500	4,0%	8,7%	4,2%	0,0%	0,0%	0,0%	96,0%	91,3%	95,8%

IM- Soluciones impropias (no convergentes/casos Heywood).



**Tabla 12.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ). Distribución x N x Estimador (Media (D.T.))

D1	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	85,6%	1,4%	,59 (.39)	,26 (.12)	,23 (.11)	,88 (.40)	84,2%	,76 (.38)	,21 (.12)	,18 (.11)	,71 (.38)
	300	93,3%	0,6%	,21 (.65)	,34 (.17)	,30 (.15)	1,15 (.56)	92,7%	,84 (.27)	<b>,17 (.08)</b>	,14 (.08)	,56 (.28)
	400	96,1%	0,0%	n.a.	n.a.	n.a.	n.a.	96,1%	,89 (.19)	<b>,14 (.07)</b>	,12 (.06)	,47 (.22)
	500	98,7%	0,0%	n.a.	n.a.	n.a.	n.a.	98,7%	<b>,92 (.14)</b>	<b>,12 (.05)</b>	<b>,10 (.05)</b>	,41 (.17)
RML	200	70,8%	1,0%	,67 (.20)	,24 (.08)	,20 (.07)	,79 (.26)	69,8%	,79 (.32)	,21 (.10)	,17 (.09)	,70 (.34)
	300	85,8%	0,6%	,24 (.59)	,32 (.13)	,29 (.12)	1,08 (.43)	85,2%	,84 (.24)	<b>,17 (.08)</b>	,14 (.07)	,58 (.27)
	400	92,6%	0,0%	n.a.	n.a.	n.a.	n.a.	92,6%	,88 (.18)	<b>,15 (.07)</b>	,12 (.06)	,49 (.22)
	500	96,7%	0,0%	n.a.	n.a.	n.a.	n.a.	96,7%	,91 (.13)	<b>,13 (.05)</b>	,11 (.05)	,43 (.18)
RULS	200	84,9%	1,5%	,59 (.37)	,26 (.12)	,23 (.10)	,87 (.39)	83,4%	,77 (.37)	,21 (.11)	,17 (.10)	,70 (.38)
	300	93,2%	0,6%	,21 (.65)	,35 (.17)	,30 (.15)	1,15 (.56)	92,6%	,85 (.26)	<b>,17 (.08)</b>	,14 (.07)	,56 (.27)
	400	95,9%	0,0%	n.a.	n.a.	n.a.	n.a.	95,9%	,89 (.19)	<b>,14 (.07)</b>	,12 (.06)	,47 (.22)
	500	98,7%	0,0%	n.a.	n.a.	n.a.	n.a.	98,7%	<b>,92 (.10)</b>	<b>,12 (.04)</b>	<b>,10 (.04)</b>	,41 (.15)
D2	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	84,8%	1,6%	,63 (.35)	,25 (.10)	,21 (.09)	,84 (.32)	83,2%	,76 (.36)	,22 (.11)	,18 (.10)	,72 (.37)
	300	92,6%	0,6%	,63 (.15)	,26 (.05)	,21 (.05)	,86 (.18)	92,0%	,83 (.30)	<b>,17 (.09)</b>	,15 (.09)	,58 (.31)
	400	95,7%	0,1%	,80 (.00)	<b>,19 (.00)</b>	,16 (.00)	,64 (.00)	95,6%	,88 (.20)	<b>,15 (.07)</b>	,12 (.06)	,48 (.22)
	500	97,7%	0,0%	n.a.	n.a.	n.a.	n.a.	97,7%	<b>,92 (.12)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,41 (.17)
RML	200	72,6%	1,3%	,60 (.37)	,27 (.10)	,22 (.09)	,89 (.34)	71,3%	,77 (.34)	,22 (.10)	,18 (.09)	,73 (.35)
	300	83,4%	0,5%	,60 (.14)	,30 (.07)	,26 (.06)	1,00 (.23)	82,9%	,84 (.26)	<b>,18 (.08)</b>	,14 (.07)	,58 (.27)
	400	90,9%	0,1%	,77 (.00)	,20 (.00)	,16 (.00)	,68 (.00)	90,8%	,88 (.18)	<b>,15 (.06)</b>	,12 (.06)	,50 (.21)
	500	95,7%	0,0%	n.a.	n.a.	n.a.	n.a.	95,7%	,91 (.11)	<b>,13 (.05)</b>	,11 (.04)	,43 (.16)
RULS	200	84,9%	1,6%	,63 (.35)	,25 (.10)	,21 (.09)	,84 (.33)	83,3%	,76 (.38)	,22 (.11)	,18 (.10)	,72 (.38)
	300	92,3%	0,6%	,63 (.14)	,26 (.05)	,21 (.05)	,86 (.18)	91,7%	,84 (.28)	<b>,17 (.09)</b>	,14 (.08)	,57 (.29)
	400	95,6%	0,1%	,80 (.00)	<b>,19 (.00)</b>	,16 (.00)	,64 (.00)	95,5%	,88 (.20)	<b>,15 (.07)</b>	,12 (.06)	,49 (.23)
	500	97,4%	0,0%	n.a.	n.a.	n.a.	n.a.	97,4%	<b>,92 (.11)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,41 (.16)
D3	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
RDWLS	200	79,4%	1,8%	,69 (.34)	,26 (.11)	,21 (.10)	,86 (.37)	77,6%	,68 (.45)	,26 (.13)	,21 (.12)	,85 (.44)
	300	86,3%	0,8%	,68 (.50)	,22 (.17)	,18 (.14)	,75 (.56)	85,5%	,79 (.34)	,20 (.10)	,16 (.09)	,66 (.34)
	400	93,2%	0,1%	,84 (.00)	<b>,16 (.00)</b>	,12 (.00)	,55 (.00)	93,1%	,83 (.29)	<b>,17 (.09)</b>	,14 (.08)	,58 (.30)
	500	96,0%	0,0%	n.a.	n.a.	n.a.	n.a.	96,0%	,87 (.22)	<b>,15 (.07)</b>	,12 (.06)	,50 (.24)
RML	200	59,9%	1,4%	,67 (.36)	,26 (.11)	,22 (.09)	,86 (.37)	58,5%	,70 (.41)	,25 (.12)	,21 (.11)	,85 (.41)
	300	72,9%	0,8%	,65 (.49)	,25 (.16)	,21 (.13)	,84 (.53)	72,1%	,80 (.31)	,20 (.10)	,16 (.09)	,67 (.32)
	400	82,4%	0,1%	,81 (.00)	<b>,18 (.00)</b>	,14 (.00)	,59 (.00)	82,3%	,83 (.26)	<b>,18 (.08)</b>	,15 (.08)	,59 (.28)
	500	91,3%	0,0%	n.a.	n.a.	n.a.	n.a.	91,3%	,86 (.21)	<b>,16 (.07)</b>	,13 (.06)	,52 (.25)
RULS	200	77,5%	1,8%	,68 (.34)	,25 (.11)	,21 (.09)	,85 (.36)	75,7%	,69 (.42)	,25 (.13)	,21 (.11)	,84 (.42)
	300	84,6%	0,8%	,68 (.50)	,23 (.16)	,19 (.14)	,76 (.55)	83,8%	,79 (.33)	,20 (.10)	,16 (.09)	,66 (.33)
	400	92,1%	0,1%	,83 (.00)	<b>,17 (.00)</b>	,13 (.00)	,57 (.00)	92,0%	,83 (.29)	<b>,17 (.09)</b>	,14 (.08)	,58 (.30)
	500	95,8%	0,0%	n.a.	n.a.	n.a.	n.a.	95,8%	,87 (.22)	<b>,15 (.07)</b>	,12 (.06)	,50 (.24)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene H<sub>0</sub> del Modelo de Independencia; T1 - % soluciones en las que se rechaza H<sub>0</sub> del Modelo de Independencia.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones (C<sub>j</sub> ≥ 0,92, RMSD<sub>j</sub> < 0,2, ARB<sub>j</sub> ≤ 0,10 y AMSE<sub>j</sub> ≤ 0,10).

n.a. – No aplicable.

**Tabla 12.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).*Distribución x N x Estimador (Media (D.T.) sobre soluciones válidas)*

<b>D1</b>	<i>N</i>	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$			
		$\chi^2_0 (p-v)$	<i>ECVI<sub>r</sub></i>	<i>AIC<sub>r</sub></i>	<i>CAIC<sub>r</sub></i>	$\chi^2_0 (p-v)$	<i>ECVI<sub>r</sub></i>	<i>AIC<sub>r</sub></i>	<i>CAIC<sub>r</sub></i>
<i>RDWLS</i>	200	<b>3,31</b> (,933)	,99 (,09)	<b>1,21</b> (,10)	,744 (,03)	<b>9,17</b> (,504)	<b>2,21</b> (,61)	<b>2,35</b> (,63)	<b>1,21</b> (,25)
	300	<b>3,75</b> (,900)	<b>1,02</b> (,09)	<b>1,22</b> (,10)	,736 (,03)	<b>9,10</b> (,499)	<b>2,53</b> (,74)	<b>2,68</b> (,76)	<b>1,29</b> (,28)
	400	n.a.	n.a.	n.a.	n.a.	<b>9,16</b> (,491)	<b>2,87</b> (,83)	<b>3,03</b> (,88)	<b>1,39</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,94</b> (,504)	<b>3,22</b> (,95)	<b>3,40</b> (1,00)	<b>1,49</b> (,34)
<i>RML</i>	200	<b>3,72</b> (,905)	,99 (,08)	<b>1,19</b> (,13)	,739 (,04)	<b>8,87</b> (,525)	<b>2,25</b> (,63)	<b>2,41</b> (,65)	<b>1,23</b> (,25)
	300	<b>3,89</b> (,887)	<b>1,02</b> (,09)	<b>1,22</b> (,09)	,735 (,03)	<b>8,83</b> (,514)	<b>2,56</b> (,76)	<b>2,72</b> (,77)	<b>1,31</b> (,29)
	400	n.a.	n.a.	n.a.	n.a.	<b>9,04</b> (,499)	<b>2,90</b> (,84)	<b>3,06</b> (,88)	<b>1,40</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,88</b> (,507)	<b>3,24</b> (,94)	<b>3,43</b> (,99)	<b>1,50</b> (,33)
<i>RULS</i>	200	<b>3,44</b> (,925)	,98 (,09)	<b>1,19</b> (,12)	,738 (,04)	<b>9,19</b> (,503)	<b>2,22</b> (,61)	<b>2,36</b> (,63)	<b>1,21</b> (,25)
	300	<b>3,75</b> (,900)	<b>1,02</b> (,09)	<b>1,22</b> (,10)	,736 (,03)	<b>9,09</b> (,499)	<b>2,53</b> (,74)	<b>2,68</b> (,76)	<b>1,29</b> (,28)
	400	n.a.	n.a.	n.a.	n.a.	<b>9,17</b> (,490)	<b>2,88</b> (,83)	<b>3,03</b> (,87)	<b>1,39</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,94</b> (,503)	<b>3,22</b> (,95)	<b>3,40</b> (1,00)	<b>1,49</b> (,34)
<b>D2</b>	<i>N</i>	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$			
		$\chi^2_0 (p-v)$	<i>ECVI<sub>r</sub></i>	<i>AIC<sub>r</sub></i>	<i>CAIC<sub>r</sub></i>	$\chi^2_0 (p-v)$	<i>ECVI<sub>r</sub></i>	<i>AIC<sub>r</sub></i>	<i>CAIC<sub>r</sub></i>
<i>RDWLS</i>	200	<b>3,31</b> (,933)	,99 (,07)	<b>1,20</b> (,08)	,741 (,02)	<b>8,92</b> (,518)	<b>2,20</b> (,62)	<b>2,34</b> (,64)	<b>1,21</b> (,25)
	300	<b>3,29</b> (,927)	,99 (,12)	<b>1,20</b> (,13)	,726 (,04)	<b>9,04</b> (,502)	<b>2,54</b> (,74)	<b>2,68</b> (,76)	<b>1,30</b> (,28)
	400	<b>2,57</b> (,979)	<b>1,05</b> (,00)	<b>1,30</b> (,00)	,747 (,00)	<b>9,14</b> (,492)	<b>2,88</b> (,83)	<b>3,03</b> (,88)	<b>1,39</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,94</b> (,505)	<b>3,22</b> (,95)	<b>3,41</b> (1,00)	<b>1,49</b> (,34)
<i>RML</i>	200	<b>3,42</b> (,919)	,99 (,07)	<b>1,20</b> (,07)	,742 (,02)	<b>8,84</b> (,526)	<b>2,23</b> (,63)	<b>2,38</b> (,66)	<b>1,22</b> (,25)
	300	<b>3,63</b> (,902)	<b>1,02</b> (,10)	<b>1,23</b> (,10)	,738 (,03)	<b>8,88</b> (,511)	<b>2,57</b> (,75)	<b>2,72</b> (,76)	<b>1,31</b> (,28)
	400	<b>2,48</b> (,981)	<b>1,05</b> (,00)	<b>1,31</b> (,00)	,748 (,00)	<b>9,14</b> (,493)	<b>2,91</b> (,84)	<b>3,07</b> (,88)	<b>1,40</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,94</b> (,505)	<b>3,23</b> (,95)	<b>3,42</b> (1,00)	<b>1,50</b> (,34)
<i>RULS</i>	200	<b>3,31</b> (,933)	,99 (,07)	<b>1,20</b> (,08)	,741 (,02)	<b>8,95</b> (,517)	<b>2,20</b> (,62)	<b>2,35</b> (,64)	<b>1,21</b> (,25)
	300	<b>3,29</b> (,927)	,99 (,12)	<b>1,20</b> (,13)	,726 (,04)	<b>9,03</b> (,503)	<b>2,54</b> (,75)	<b>2,68</b> (,76)	<b>1,30</b> (,28)
	400	<b>2,57</b> (,979)	<b>1,05</b> (,00)	<b>1,30</b> (,00)	,747 (,00)	<b>9,14</b> (,492)	<b>2,88</b> (,84)	<b>3,03</b> (,88)	<b>1,39</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,94</b> (,505)	<b>3,22</b> (,95)	<b>3,41</b> (1,00)	<b>1,49</b> (,34)
<b>D3</b>	<i>N</i>	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,3; n = 6)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$			
		$\chi^2_0 (p-v)$	<i>ECVI<sub>r</sub></i>	<i>AIC<sub>r</sub></i>	<i>CAIC<sub>r</sub></i>	$\chi^2_0 (p-v)$	<i>ECVI<sub>r</sub></i>	<i>AIC<sub>r</sub></i>	<i>CAIC<sub>r</sub></i>
<i>RDWLS</i>	200	<b>3,17</b> (,943)	,96 (,09)	<b>1,17</b> (,10)	,732 (,03)	<b>9,06</b> (,508)	<b>2,18</b> (,62)	<b>2,32</b> (,64)	<b>1,20</b> (,25)
	300	<b>3,39</b> (,922)	,98 (,11)	<b>1,18</b> (,11)	,722 (,03)	<b>8,98</b> (,506)	<b>2,52</b> (,76)	<b>2,67</b> (,78)	<b>1,29</b> (,29)
	400	<b>2,57</b> (,979)	<b>1,05</b> (,00)	<b>1,30</b> (,00)	,747 (,00)	<b>9,09</b> (,494)	<b>2,86</b> (,84)	<b>3,01</b> (,88)	<b>1,38</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,92</b> (,505)	<b>3,22</b> (,94)	<b>3,41</b> (1,00)	<b>1,49</b> (,34)
<i>RML</i>	200	<b>3,42</b> (,927)	,97 (,08)	<b>1,18</b> (,09)	,735 (,03)	<b>9,12</b> (,508)	<b>2,21</b> (,62)	<b>2,35</b> (,64)	<b>1,21</b> (,25)
	300	<b>3,48</b> (,912)	,98 (,11)	<b>1,18</b> (,11)	,722 (,03)	<b>8,93</b> (,507)	<b>2,53</b> (,76)	<b>2,68</b> (,78)	<b>1,29</b> (,29)
	400	<b>2,48</b> (,981)	<b>1,05</b> (,00)	<b>1,31</b> (,00)	,748 (,00)	<b>9,06</b> (,496)	<b>2,89</b> (,85)	<b>3,05</b> (,90)	<b>1,40</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,89</b> (,507)	<b>3,24</b> (,95)	<b>3,43</b> (1,00)	<b>1,50</b> (,34)
<i>RULS</i>	200	<b>3,20</b> (,942)	,97 (,08)	<b>1,19</b> (,10)	,735 (,03)	<b>9,02</b> (,510)	<b>2,18</b> (,62)	<b>2,33</b> (,64)	<b>1,20</b> (,25)
	300	<b>3,39</b> (,922)	,98 (,11)	<b>1,18</b> (,11)	,722 (,03)	<b>9,01</b> (,506)	<b>2,52</b> (,76)	<b>2,67</b> (,77)	<b>1,29</b> (,29)
	400	<b>2,57</b> (,979)	<b>1,05</b> (,00)	<b>1,30</b> (,00)	,747 (,00)	<b>9,16</b> (,491)	<b>2,86</b> (,84)	<b>3,02</b> (,88)	<b>1,39</b> (,31)
	500	n.a.	n.a.	n.a.	n.a.	<b>8,94</b> (,504)	<b>3,22</b> (,94)	<b>3,41</b> (1,00)	<b>1,49</b> (,34)

 $\chi^2_0 (p-v)$  - Media (nivel crítico).*ECVI<sub>r</sub>*, *AIC<sub>r</sub>*, *CAIC<sub>r</sub>* - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0; p \geq 0,05$ ) y las celdas en las que el valor *ECVI*, *AIC* o *CAIC* del modelo nulo es mayor que el del modelo evaluado (razón > 1).

n.a. - No aplicable.

**Tabla 12.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).

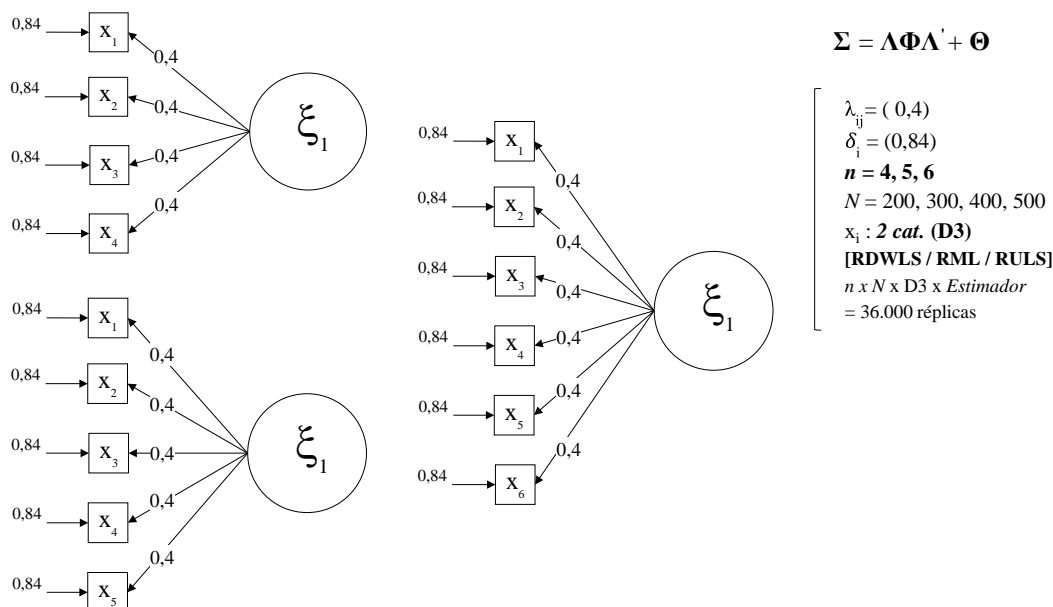
Distribución x N x Estimador (Media (D.T.) sobre soluciones válidas)

D1	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 6)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,85 (,05)	2,32 (2,57)	,74 (,08)	,93 (,26)	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,87 (,05)	1,05 (,19)	,78 (,08)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,83 (,06)	2,08 (2,63)	,72 (,11)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,88 (,04)	1,03 (,15)	,80 (,08)	<b>,98 (,03)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,02 (,13)	,82 (,07)	<b>,98 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,98 (,02)</b>
RML	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,83 (,07)	2,72 (**)	,71 (,13)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,87 (,04)	1,06 (,18)	,79 (,08)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,83 (,07)	2,08 (2,64)	,72 (,12)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,04 (,15)	,81 (,08)	<b>,98 (,02)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,90 (,04)	1,02 (,12)	,83 (,07)	<b>,99 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,99 (,02)</b>
RULS	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,84 (,06)	2,34 (8,90)	,73 (,10)	,93 (,25)	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,87 (,05)	1,05 (,18)	,78 (,08)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,83 (,06)	2,08 (2,63)	,72 (,11)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,88 (,04)	1,03 (,15)	,80 (,08)	<b>,98 (,03)</b>
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,02 (,13)	,82 (,07)	<b>,98 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,98 (,02)</b>
D2	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 6)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,85 (,04)	2,74 (2,76)	,75 (,08)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,87 (,05)	1,06 (,19)	,78 (,08)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,85 (,06)	2,03 (**)	,75 (,10)	,83 (,40)	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,88 (,04)	1,03 (,16)	,80 (,08)	<b>,98 (,03)</b>
	400	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,88 (,00)	2,36 (,00)	,80 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,02 (,13)	,82 (,07)	<b>,98 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,98 (,02)</b>
RML	200	<b>,00 (,00)</b>	<b>,04 (,01)</b>	,85 (,05)	2,74 (1,83)	,74 (,10)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,87 (,05)	1,06 (,19)	,78 (,09)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,84 (,07)	2,18 (2,87)	,74 (,12)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,03 (,15)	,81 (,08)	<b>,98 (,03)</b>
	400	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,89 (,00)	2,38 (,00)	,81 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,90 (,04)	1,02 (,13)	,83 (,08)	<b>,98 (,03)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,11)	,85 (,07)	<b>,98 (,02)</b>
RULS	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,85 (,04)	2,74 (2,76)	,75 (,08)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,87 (,05)	1,06 (,19)	,78 (,09)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,85 (,06)	2,03 (**)	,75 (,10)	,83 (,40)	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,88 (,04)	1,03 (,16)	,80 (,08)	<b>,98 (,03)</b>
	400	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,88 (,00)	2,36 (,00)	,80 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,02 (,13)	,82 (,07)	<b>,98 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,98 (,02)</b>
D3	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} = 0,3; n = 6)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,3; n = 6)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,85 (,04)	2,76 (**)	,75 (,07)	,94 (,23)	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,86 (,05)	1,05 (,19)	,77 (,09)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,84 (,05)	2,08 (**)	,73 (,10)	,88 (,35)	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,88 (,04)	1,03 (,17)	,80 (,08)	<b>,98 (,03)</b>
	400	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,88 (,00)	2,36 (,00)	,80 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,02 (,13)	,82 (,08)	<b>,98 (,03)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,98 (,02)</b>
RML	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,84 (,05)	2,72 (2,59)	,73 (,09)	,93 (,26)	<b>,01 (,02)</b>	<b>,07 (,01)</b>	,87 (,05)	1,05 (,20)	,78 (,09)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,84 (,06)	2,08 (**)	,73 (,10)	,88 (,35)	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,88 (,05)	1,03 (,17)	,80 (,08)	<b>,98 (,03)</b>
	400	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,89 (,00)	2,38 (,00)	,81 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,90 (,04)	1,02 (,13)	,83 (,08)	<b>,98 (,03)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,99 (,02)</b>
RULS	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,85 (,04)	2,74 (3,23)	,75 (,07)	,94 (,23)	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,87 (,05)	1,05 (,19)	,78 (,09)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,84 (,05)	2,08 (**)	,73 (,10)	,88 (,35)	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,88 (,04)	1,03 (,17)	,80 (,08)	<b>,98 (,03)</b>
	400	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,88 (,00)	2,36 (,00)	,80 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,89 (,04)	1,02 (,13)	,82 (,08)	<b>,98 (,03)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,01)</b>	<b>,04 (,01)</b>	,91 (,04)	1,02 (,10)	,85 (,07)	<b>,98 (,02)</b>

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

n.a. – No aplicable.

Ficha 13. Modelos simulados y síntesis de resultados ( $\lambda_{ij} = 0,4$ ,  $n = 4, 5, 6$ )**Cuadro 13.1.** Path diagram, notación matricial y condiciones simuladas**Tabla 13.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%).  $n \times N \times \text{Estimador}$ . Distribución 3.

$n$	$N$	IM ( $\lambda_{ij} = 0,4$ )			$\hat{\Sigma}_{\text{Null}}$ ( $\lambda_{ij} = 0,4$ )			$\hat{\Sigma}_0$ ( $\lambda_{ij} = 0,4$ )		
		RDWLS	RML	RULS	RDWLS	RML	RULS	RDWLS	RML	RULS
4	200	20,5%	28,1%	21,3%	1,9%	1,6%	1,8%	77,6%	70,3%	76,9%
	300	11,1%	16,3%	11,8%	0,6%	0,6%	0,6%	88,3%	83,1%	87,6%
	400	4,3%	7,4%	4,5%	0,6%	0,6%	0,6%	95,1%	92,0%	94,9%
	500	2,7%	3,7%	2,9%	0,1%	0,1%	0,1%	97,2%	96,2%	97,0%
5	200	9,3%	19,0%	10,5%	0,0%	0,0%	0,0%	90,7%	81,0%	89,5%
	300	3,5%	5,9%	3,7%	0,0%	0,0%	0,0%	96,5%	94,1%	96,3%
	400	0,9%	3,1%	0,7%	0,0%	0,0%	0,0%	99,1%	96,9%	99,3%
	500	0,4%	0,6%	0,4%	0,0%	0,0%	0,0%	99,6%	99,4%	99,6%
6	200	2,8%	12,5%	3,5%	0,0%	0,0%	0,0%	97,2%	87,5%	96,5%
	300	0,2%	3,5%	0,6%	0,0%	0,0%	0,0%	99,8%	96,5%	99,4%
	400	0,2%	0,6%	0,2%	0,0%	0,0%	0,0%	99,8%	99,4%	99,8%
	500	0,1%	0,2%	0,1%	0,0%	0,0%	0,0%	99,9%	99,8%	99,9%

IM- Soluciones impropias (no convergentes/casos Heywood).

Distribución 3: 0 – 75%, 1 – 25%.

**Tabla 13.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null} (\alpha = 0,05)$ .  $n \times N \times N$  Estimador (Media (D.T.)) Distribución 3.

$n = 4$	$N$	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$				
			$T2$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$T1$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
RDWLS	200	79,5%	1,9%	,72 (.33)	,26 (.12)	,22 (.10)	,64 (.29)	77,6%	,90 (.18)	<b>,19 (.09)</b>	,16 (.08)	,48 (.23)
	300	88,9%	0,6%	,73 (.16)	,27 (.08)	,24 (.08)	,68 (.19)	88,3%	,91 (.19)	<b>,17 (.09)</b>	,14 (.08)	,42 (.23)
	400	95,7%	0,6%	,90 (.10)	<b>,18 (.07)</b>	,16 (.06)	,44 (.17)	95,1%	<b>,94 (.10)</b>	<b>,15 (.07)</b>	,12 (.06)	,36 (.17)
	500	97,3%	0,1%	<b>,99 (.00)</b>	<b>,06 (.00)</b>	<b>,05 (.00)</b>	,15 (.00)	97,2%	<b>,95 (.05)</b>	<b>,13 (.06)</b>	,11 (.05)	,32 (.14)
RML	200	71,9%	1,6%	,71 (.34)	,26 (.12)	,22 (.11)	,64 (.31)	70,3%	,90 (.17)	,20 (.09)	,16 (.08)	,49 (.23)
	300	83,7%	0,6%	,72 (.16)	,28 (.08)	,25 (.08)	,69 (.20)	83,1%	,91 (.16)	<b>,17 (.08)</b>	,14 (.07)	,42 (.20)
	400	92,6%	0,6%	,89 (.10)	<b>,18 (.07)</b>	,16 (.06)	,44 (.17)	92,0%	<b>,93 (.09)</b>	<b>,15 (.06)</b>	,13 (.06)	,37 (.16)
	500	96,3%	0,1%	<b>,99 (.00)</b>	<b>,06 (.00)</b>	<b>,05 (.00)</b>	,15 (.00)	96,2%	<b>,95 (.05)</b>	<b>,13 (.06)</b>	,11 (.05)	,33 (.14)
RULS	200	78,7%	1,8%	,71 (.33)	,26 (.12)	,23 (.11)	,65 (.30)	76,9%	,90 (.18)	<b>,19 (.09)</b>	,16 (.08)	,48 (.23)
	300	88,2%	0,6%	,73 (.16)	,27 (.08)	,24 (.08)	,68 (.19)	87,6%	<b>,92 (.16)</b>	<b>,17 (.08)</b>	,14 (.07)	,42 (.20)
	400	95,5%	0,6%	,90 (.10)	<b>,18 (.07)</b>	,16 (.06)	,44 (.17)	94,9%	<b>,94 (.09)</b>	<b>,15 (.07)</b>	,12 (.06)	,37 (.17)
	500	97,1%	0,1%	<b>,99 (.00)</b>	<b>,06 (.00)</b>	<b>,05 (.00)</b>	,15 (.00)	97,0%	<b>,95 (.05)</b>	<b>,13 (.06)</b>	,11 (.05)	,33 (.14)
$n = 5$	$N$	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$				
			$T2$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$T1$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
RDWLS	200	90,7%	0,0%	n.a.	n.a.	n.a.	n.a.	90,7%	,90 (.19)	<b>,16 (.08)</b>	,15 (.08)	,45 (.22)
	300	96,5%	0,0%	n.a.	n.a.	n.a.	n.a.	96,5%	<b>,94 (.09)</b>	<b>,13 (.05)</b>	,12 (.05)	,36 (.14)
	400	99,1%	0,0%	n.a.	n.a.	n.a.	n.a.	99,1%	<b>,95 (.07)</b>	<b>,11 (.05)</b>	,11 (.04)	,32 (.13)
	500	99,6%	0,0%	n.a.	n.a.	n.a.	n.a.	99,6%	<b>,96 (.03)</b>	<b>,10 (.04)</b>	<b>,09 (.03)</b>	,28 (.09)
RML	200	81,0%	0,0%	n.a.	n.a.	n.a.	n.a.	81,0%	,89 (.17)	<b>,17 (.08)</b>	,16 (.07)	,47 (.20)
	300	94,1%	0,0%	n.a.	n.a.	n.a.	n.a.	94,1%	<b>,93 (.10)</b>	<b>,14 (.06)</b>	,13 (.05)	,39 (.15)
	400	96,9%	0,0%	n.a.	n.a.	n.a.	n.a.	96,9%	<b>,95 (.05)</b>	<b>,12 (.05)</b>	,11 (.04)	,33 (.12)
	500	99,4%	0,0%	n.a.	n.a.	n.a.	n.a.	99,4%	<b>,96 (.04)</b>	<b>,10 (.04)</b>	<b>,10 (.04)</b>	,29 (.11)
RULS	200	89,5%	0,0%	n.a.	n.a.	n.a.	n.a.	89,5%	,90 (.18)	<b>,16 (.08)</b>	,15 (.08)	,46 (.21)
	300	96,3%	0,0%	n.a.	n.a.	n.a.	n.a.	96,3%	<b>,94 (.07)</b>	<b>,13 (.05)</b>	,12 (.05)	,36 (.13)
	400	99,3%	0,0%	n.a.	n.a.	n.a.	n.a.	99,3%	<b>,95 (.05)</b>	<b>,11 (.05)</b>	,11 (.04)	,32 (.12)
	500	99,6%	0,0%	n.a.	n.a.	n.a.	n.a.	99,6%	<b>,96 (.03)</b>	<b>,10 (.04)</b>	<b>,09 (.03)</b>	,28 (.10)
$n = 6$	$N$	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$					$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$				
			$T2$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$T1$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
RDWLS	200	97,2%	0,0%	n.a.	n.a.	n.a.	n.a.	97,2%	,90 (.21)	<b>,14 (.07)</b>	,15 (.08)	,43 (.22)
	300	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,94 (.09)</b>	<b>,11 (.05)</b>	,11 (.05)	,34 (.13)
	400	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,95 (.10)</b>	<b>,09 (.04)</b>	<b>,10 (.05)</b>	,29 (.12)
	500	99,9%	0,0%	n.a.	n.a.	n.a.	n.a.	99,9%	<b>,97 (.02)</b>	<b>,08 (.03)</b>	<b>,08 (.03)</b>	,25 (.08)
RML	200	87,5%	0,0%	n.a.	n.a.	n.a.	n.a.	87,5%	,91 (.14)	<b>,14 (.06)</b>	,15 (.06)	,44 (.17)
	300	96,5%	0,0%	n.a.	n.a.	n.a.	n.a.	96,5%	<b>,93 (.09)</b>	<b>,11 (.05)</b>	,12 (.05)	,36 (.14)
	400	99,4%	0,0%	n.a.	n.a.	n.a.	n.a.	99,4%	<b>,95 (.09)</b>	<b>,10 (.04)</b>	<b>,10 (.04)</b>	,31 (.12)
	500	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,96 (.03)</b>	<b>,08 (.03)</b>	<b>,09 (.03)</b>	,27 (.09)
RULS	200	96,5%	0,0%	n.a.	n.a.	n.a.	n.a.	96,5%	,90 (.20)	<b>,14 (.07)</b>	,15 (.08)	,43 (.21)
	300	99,4%	0,0%	n.a.	n.a.	n.a.	n.a.	99,4%	<b>,94 (.11)</b>	<b>,11 (.05)</b>	,11 (.05)	,34 (.14)
	400	99,8%	0,0%	n.a.	n.a.	n.a.	n.a.	99,8%	<b>,96 (.09)</b>	<b>,09 (.04)</b>	<b>,10 (.04)</b>	,29 (.11)
	500	99,9%	0,0%	n.a.	n.a.	n.a.	n.a.	99,9%	<b>,97 (.02)</b>	<b>,08 (.03)</b>	<b>,08 (.03)</b>	,25 (.08)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del Modelo de Independencia; T1 - % soluciones en las que se rechaza  $H_0$  del Modelo de Independencia.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

n.a. - No aplicable.

**Tabla 13.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ). $n \times N \times$  Estimador (Media (D.T.) sobre soluciones válidas). Distribución 3.

$n = 4$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
RDWLS	200	<b>,65 (,743)</b>	,99 (,10)	<b>1,08 (,11)</b>	,688 (,03)	<b>1,84 (,522)</b>	<b>3,34 (1,31)</b>	<b>3,49 (1,38)</b>	<b>1,52 (,46)</b>
	300	<b>,19 (,909)</b>	,90 (,14)	<b>1,00 (,16)</b>	,652 (,05)	<b>1,85 (,523)</b>	<b>4,08 (1,58)</b>	<b>4,27 (1,67)</b>	<b>1,71 (,52)</b>
	400	<b>,36 (,847)</b>	<b>1,02 (,12)</b>	<b>1,12 (,12)</b>	,680 (,03)	<b>1,89 (,518)</b>	<b>4,86 (1,80)</b>	<b>5,08 (1,90)</b>	<b>1,91 (,57)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>1,77 (,530)</b>	<b>5,67 (2,00)</b>	<b>5,94 (2,11)</b>	<b>2,12 (,62)</b>
RML	200	<b>,61 (,755)</b>	<b>1,00 (,10)</b>	<b>1,09 (,11)</b>	,691 (,03)	<b>1,67 (,548)</b>	<b>3,38 (1,35)</b>	<b>3,55 (1,42)</b>	<b>1,53 (,47)</b>
	300	<b>,20 (,908)</b>	,90 (,14)	<b>1,00 (,16)</b>	,652 (,05)	<b>1,73 (,538)</b>	<b>4,14 (1,59)</b>	<b>4,34 (1,68)</b>	<b>1,72 (,53)</b>
	400	<b>,36 (,846)</b>	<b>1,02 (,12)</b>	<b>1,12 (,12)</b>	,680 (,03)	<b>1,81 (,528)</b>	<b>4,90 (1,80)</b>	<b>5,13 (1,90)</b>	<b>1,92 (,57)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>1,77 (,531)</b>	<b>5,69 (1,99)</b>	<b>5,96 (2,11)</b>	<b>2,12 (,61)</b>
RULS	200	<b>,58 (,765)</b>	,99 (,10)	<b>1,08 (,11)</b>	,688 (,03)	<b>1,82 (,525)</b>	<b>3,35 (1,31)</b>	<b>3,50 (1,38)</b>	<b>1,52 (,46)</b>
	300	<b>,19 (,909)</b>	,90 (,14)	<b>1,00 (,16)</b>	,652 (,05)	<b>1,82 (,525)</b>	<b>4,09 (1,58)</b>	<b>4,28 (1,67)</b>	<b>1,71 (,52)</b>
	400	<b>,36 (,847)</b>	<b>1,02 (,12)</b>	<b>1,12 (,12)</b>	,680 (,03)	<b>1,88 (,519)</b>	<b>4,86 (1,80)</b>	<b>5,09 (1,90)</b>	<b>1,91 (,57)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>1,77 (,530)</b>	<b>5,68 (2,00)</b>	<b>5,95 (2,11)</b>	<b>2,12 (,62)</b>
$n = 5$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
RDWLS	200	n.a.	n.a.	n.a.	n.a.	<b>5,21 (,487)</b>	<b>3,58 (1,15)</b>	<b>3,77 (1,22)</b>	<b>1,69 (,44)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>5,00 (,504)</b>	<b>4,52 (1,41)</b>	<b>4,78 (1,51)</b>	<b>1,97 (,51)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>5,13 (,494)</b>	<b>5,47 (1,74)</b>	<b>5,78 (1,88)</b>	<b>2,24 (,59)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>5,21 (,485)</b>	<b>6,42 (1,91)</b>	<b>6,77 (2,10)</b>	<b>2,51 (,63)</b>
RML	200	n.a.	n.a.	n.a.	n.a.	<b>4,90 (,512)</b>	<b>3,65 (1,18)</b>	<b>3,87 (1,24)</b>	<b>1,72 (,45)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>4,99 (,507)</b>	<b>4,56 (1,41)</b>	<b>4,82 (1,50)</b>	<b>1,98 (,50)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>5,04 (,500)</b>	<b>5,51 (1,73)</b>	<b>5,82 (1,87)</b>	<b>2,25 (,59)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>5,21 (,485)</b>	<b>6,42 (1,91)</b>	<b>6,78 (2,09)</b>	<b>2,52 (,63)</b>
RULS	200	n.a.	n.a.	n.a.	n.a.	<b>5,15 (,491)</b>	<b>3,59 (1,16)</b>	<b>3,79 (1,22)</b>	<b>1,70 (,44)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>5,01 (,504)</b>	<b>4,53 (1,42)</b>	<b>4,79 (1,51)</b>	<b>1,97 (,51)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>5,14 (,493)</b>	<b>5,46 (1,74)</b>	<b>5,77 (1,88)</b>	<b>2,24 (,60)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>5,21 (,485)</b>	<b>6,42 (1,91)</b>	<b>6,78 (2,10)</b>	<b>2,51 (,63)</b>
$n = 6$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$				$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
RDWLS	200	n.a.	n.a.	n.a.	n.a.	<b>9,67 (,472)</b>	<b>3,91 (1,17)</b>	<b>4,15 (1,26)</b>	<b>1,90 (,47)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>9,62 (,467)</b>	<b>5,01 (1,44)</b>	<b>5,30 (1,56)</b>	<b>2,25 (,55)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>9,46 (,474)</b>	<b>6,08 (1,71)</b>	<b>6,42 (1,85)</b>	<b>2,58 (,62)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>9,45 (,471)</b>	<b>7,22 (1,95)</b>	<b>7,61 (2,11)</b>	<b>2,93 (,69)</b>
RML	200	n.a.	n.a.	n.a.	n.a.	<b>9,34 (,491)</b>	<b>4,02 (1,17)</b>	<b>4,28 (1,25)</b>	<b>1,94 (,47)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>9,44 (,475)</b>	<b>5,07 (1,43)</b>	<b>5,37 (1,54)</b>	<b>2,27 (,54)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>9,48 (,473)</b>	<b>6,10 (1,70)</b>	<b>6,44 (1,84)</b>	<b>2,59 (,62)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>9,47 (,471)</b>	<b>7,22 (1,95)</b>	<b>7,62 (2,11)</b>	<b>2,94 (,69)</b>
RULS	200	n.a.	n.a.	n.a.	n.a.	<b>9,64 (,474)</b>	<b>3,92 (1,17)</b>	<b>4,16 (1,26)</b>	<b>1,91 (,47)</b>
	300	n.a.	n.a.	n.a.	n.a.	<b>9,61 (,468)</b>	<b>5,02 (1,44)</b>	<b>5,31 (1,56)</b>	<b>2,26 (,55)</b>
	400	n.a.	n.a.	n.a.	n.a.	<b>9,46 (,474)</b>	<b>6,09 (1,71)</b>	<b>6,43 (1,85)</b>	<b>2,58 (,62)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>9,46 (,471)</b>	<b>7,22 (1,95)</b>	<b>7,62 (2,11)</b>	<b>2,93 (,69)</b>

 $\chi^2_0 (p-v)$  - Media (nivel crítico). $ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ ;  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.

**Tabla 13.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

$n \times N \times$  Estimador (Media (D.T.) sobre soluciones válidas). Distribución 3.

$n = 4$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	,00 (.00)	,03 (.01)	,94 (.04)	2,10 (2,00)	,81 (.14)	1,0 (.00)	,02 (.03)	,04 (.02)	,96 (.03)	1,04 (.15)	,89 (.10)	,99 (.02)
	300	,00 (.00)	,01 (.00)	,97 (.02)	2,27 (4,07)	,91 (.09)	,67 (.51)	,02 (.03)	,04 (.01)	,97 (.02)	1,04 (.11)	,91 (.08)	,99 (.02)
	400	,00 (.00)	,02 (.01)	,97 (.03)	2,15 (1,34)	,90 (.10)	1,0 (.00)	,02 (.02)	,03 (.01)	,98 (.02)	1,03 (.10)	,93 (.07)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,03 (.01)	,98 (.01)	1,02 (.07)	,94 (.06)	,99 (.01)
RML	200	,00 (.00)	,03 (.01)	,94 (.04)	2,07 (2,10)	,82 (.13)	1,0 (.00)	,02 (.03)	,04 (.02)	,97 (.02)	1,05 (.15)	,91 (.09)	,99 (.02)
	300	,00 (.00)	,01 (.00)	,97 (.02)	2,27 (4,07)	,91 (.09)	,67 (.51)	,01 (.03)	,04 (.01)	,97 (.02)	1,04 (.11)	,92 (.07)	,99 (.01)
	400	,00 (.00)	,02 (.01)	,97 (.03)	2,15 (1,34)	,90 (.10)	1,0 (.00)	,01 (.02)	,03 (.01)	,98 (.02)	1,03 (.09)	,93 (.07)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,03 (.01)	,98 (.01)	1,02 (.07)	,94 (.06)	,99 (.01)
RULS	200	,00 (.00)	,03 (.01)	,94 (.04)	2,17 (2,01)	,83 (.12)	1,0 (.00)	,02 (.03)	,04 (.02)	,97 (.03)	1,04 (.15)	,90 (.09)	,99 (.02)
	300	,00 (.00)	,01 (.00)	,97 (.02)	2,27 (4,07)	,91 (.09)	,67 (.51)	,02 (.03)	,04 (.01)	,97 (.02)	1,04 (.11)	,91 (.08)	,99 (.01)
	400	,00 (.00)	,02 (.01)	,97 (.03)	2,15 (1,34)	,90 (.10)	1,0 (.00)	,01 (.02)	,03 (.01)	,98 (.02)	1,03 (.10)	,93 (.07)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,03 (.01)	,98 (.01)	1,02 (.07)	,94 (.06)	,99 (.01)
$n = 5$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,02 (.03)	,06 (.02)	,94 (.03)	1,02 (.10)	,88 (.07)	,99 (.02)
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,95 (.03)	1,02 (.07)	,90 (.06)	,99 (.02)
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,96 (.02)	1,01 (.06)	,92 (.05)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,04 (.01)	,97 (.02)	1,01 (.05)	,93 (.05)	,99 (.01)
RML	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,02 (.02)	,06 (.02)	,94 (.03)	1,03 (.10)	,89 (.06)	,99 (.02)
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,95 (.02)	1,02 (.07)	,91 (.06)	,99 (.01)
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,96 (.02)	1,01 (.06)	,92 (.05)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,04 (.01)	,97 (.02)	1,01 (.05)	,93 (.04)	,99 (.01)
RULS	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,02 (.03)	,06 (.02)	,94 (.03)	1,03 (.10)	,88 (.07)	,99 (.02)
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,95 (.03)	1,02 (.07)	,91 (.06)	,99 (.02)
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,96 (.02)	1,01 (.06)	,92 (.05)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,04 (.01)	,97 (.02)	1,01 (.05)	,93 (.05)	,99 (.01)
$n = 6$	$N$	$\hat{\Sigma}_{Null} (\lambda_{ij} = 0,4)$						$\hat{\Sigma}_0 (\lambda_{ij} = 0,4)$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
RDWLS	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,02 (.02)	,07 (.01)	,93 (.03)	1,02 (.08)	,88 (.06)	,99 (.02)
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,06 (.01)	,94 (.02)	1,01 (.06)	,90 (.05)	,99 (.01)
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,95 (.02)	1,01 (.04)	,92 (.04)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,96 (.02)	1,00 (.04)	,93 (.03)	,99 (.01)
RML	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,07 (.01)	,93 (.03)	1,02 (.07)	,89 (.05)	,99 (.01)
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,06 (.01)	,94 (.02)	1,01 (.05)	,91 (.04)	,99 (.01)
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,95 (.02)	1,01 (.04)	,92 (.04)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,96 (.02)	1,00 (.03)	,93 (.03)	,99 (.01)
RULS	200	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,02 (.02)	,07 (.01)	,93 (.03)	1,02 (.08)	,88 (.06)	,99 (.02)
	300	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,06 (.01)	,94 (.02)	1,01 (.06)	,90 (.05)	,99 (.01)
	400	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,95 (.02)	1,01 (.04)	,92 (.04)	,99 (.01)
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	,01 (.02)	,05 (.01)	,96 (.02)	1,00 (.04)	,93 (.03)	,99 (.01)

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

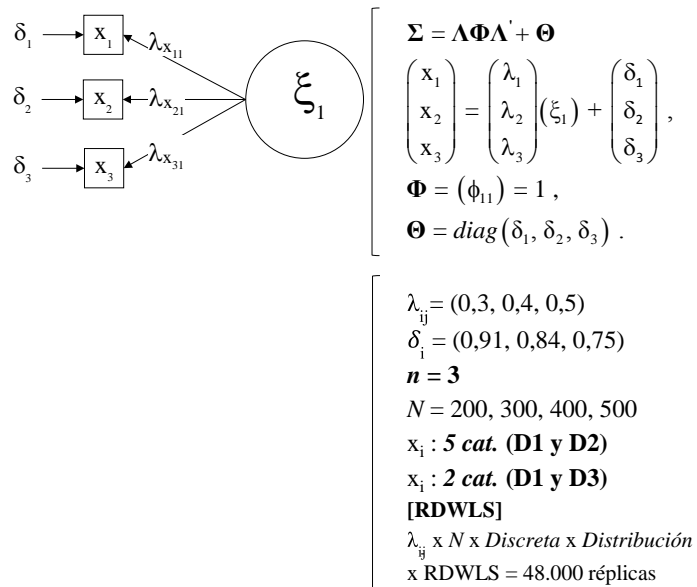
<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

n.a. – No aplicable.

## E. Estudios adicionales

Ficha 14. Factores compuestos por  $n = 3$  variables observables ( $\lambda_{ij} = 0,3, 0,4$  y  $0,5$ )

**Cuadro 14.1.** Path diagram, notación matricial y condiciones simuladas



**Tabla 14.1.** Soluciones impropias.  $\lambda_{ij} \times \text{Distribución} \times N$ .

$\lambda_{ij}$	$N$	IM			
		5 categorías		Dicotómicos	
		5D1	5D2	2D1	2D3
0,3	200	35,7%	50,1%	49,9%	52,5%
	300	26,2%	42,5%	44,1%	46,9%
	400	18,4%	36,4%	37,7%	46,0%
	500	14,0%	35,4%	33,0%	38,3%
0,4	200	12,8%	32,7%	33,3%	38,5%
	300	4,9%	22,3%	20,1%	29,4%
	400	2,1%	16,9%	12,6%	20,3%
	500	0,9%	10,3%	9,3%	15,1%
0,5	200	2,4%	16,6%	14,0%	21,2%
	300	0,7%	8,0%	4,6%	10,8%
	400	0,0%	4,3%	2,1%	5,7%
	500	0,0%	1,8%	1,4%	3,1%

IM- Soluciones impropias (no convergentes/casos *Heywood*).

5 categorías: 5D1 y 5D2 - Caso 1 y 4 (Muthén y Kaplan, 1992).

Dicotómicos: 2D1 y 2D3 – 50%-50% y 75%-25%.



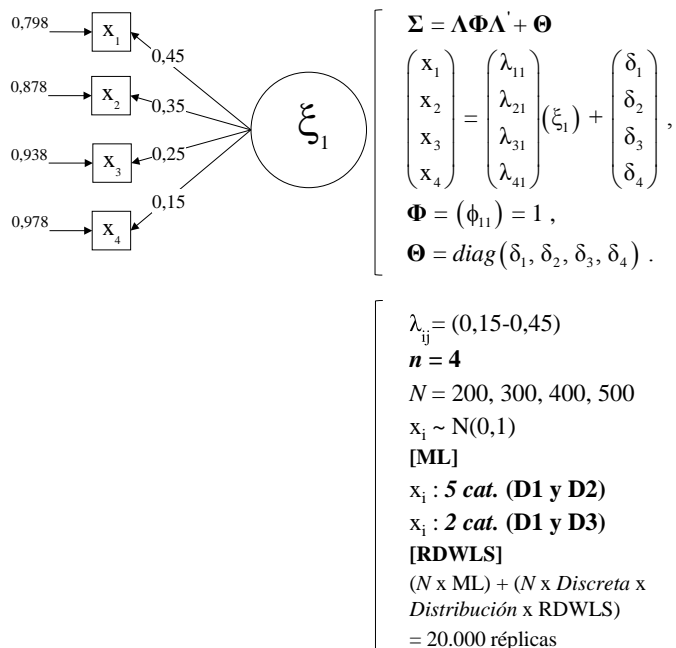
**Tabla 14.2.** Ajuste teórico de las soluciones válidas.  $\lambda_{ij}$  x Distribución x  $N$ .

$\lambda_{ij}$	$N$	5 categorías (5D1)				5 categorías (5D2)			
		$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
0,3	200	,87 (.22)	<b>,18 (.10)</b>	,16 (.09)	,61 (.34)	,74 (.42)	,25 (.15)	,21 (.12)	,85 (.48)
	300	,90 (.17)	<b>,16 (.09)</b>	,14 (.08)	,54 (.31)	,81 (.31)	,22 (.12)	,18 (.10)	,74 (.40)
	400	<b>,92 (.08)</b>	<b>,15 (.08)</b>	,13 (.07)	,49 (.28)	,84 (.26)	,20 (.11)	,16 (.09)	,66 (.38)
	500	<b>,92 (.09)</b>	<b>,13 (.07)</b>	,11 (.06)	,44 (.25)	,87 (.23)	<b>,18 (.11)</b>	,15 (.09)	,60 (.36)
0,4	200	<b>,94 (.08)</b>	<b>,15 (.08)</b>	,13 (.07)	,37 (.19)	,91 (.17)	<b>,19 (.10)</b>	,16 (.09)	,48 (.25)
	300	<b>,95 (.05)</b>	<b>,13 (.07)</b>	,11 (.06)	,32 (.17)	<b>,93 (.11)</b>	<b>,17 (.08)</b>	,15 (.07)	,42 (.20)
	400	<b>,96 (.04)</b>	<b>,11 (.06)</b>	<b>,10 (.05)</b>	,28 (.15)	<b>,94 (.10)</b>	<b>,15 (.08)</b>	,13 (.07)	,38 (.20)
	500	<b>,97 (.04)</b>	<b>,10 (.05)</b>	<b>,09 (.05)</b>	,25 (.14)	<b>,94 (.06)</b>	<b>,14 (.07)</b>	,12 (.07)	,36 (.18)
0,5	200	<b>,97 (.03)</b>	<b>,12 (.06)</b>	<b>,10 (.05)</b>	,24 (.12)	<b>,96 (.04)</b>	<b>,16 (.07)</b>	,14 (.07)	,31 (.14)
	300	<b>,98 (.02)</b>	<b>,10 (.05)</b>	<b>,08 (.04)</b>	,19 (.09)	<b>,96 (.04)</b>	<b>,14 (.07)</b>	,12 (.06)	,28 (.13)
	400	<b>,99 (.02)</b>	<b>,08 (.04)</b>	<b>,07 (.04)</b>	,16 (.08)	<b>,97 (.03)</b>	<b>,12 (.06)</b>	,11 (.06)	,24 (.12)
	500	<b>,99 (.01)</b>	<b>,07 (.03)</b>	<b>,06 (.03)</b>	,15 (.07)	<b>,98 (.03)</b>	<b>,11 (.05)</b>	<b>,10 (.05)</b>	,22 (.11)
$\lambda_{ij}$	$N$	Dicotómicos (2D1)				Dicotómicos (2D3)			
		$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$	$C_j$	$RMSD_j$	$ARB_j$	$AMSE_j$
0,3	200	,77 (.35)	,24 (.12)	0,20 (.10)	0,80 (.42)	,71 (.43)	,27 (.16)	0,23 (.13)	0,91 (.52)
	300	,84 (.27)	,21 (.11)	0,17 (.09)	0,70 (.38)	,80 (.33)	,23 (.13)	0,19 (.10)	0,77 (.42)
	400	,87 (.22)	<b>,18 (.10)</b>	0,15 (.09)	0,62 (.35)	,83 (.28)	,21 (.11)	0,17 (.09)	0,69 (.38)
	500	,89 (.15)	<b>,17 (.10)</b>	0,14 (.08)	0,56 (.32)	,85 (.26)	,20 (.11)	0,16 (.10)	0,66 (.38)
0,4	200	,91 (.16)	<b>,19 (.09)</b>	0,16 (.08)	0,47 (.23)	,88 (.23)	,20 (.11)	0,17 (.10)	0,51 (.28)
	300	<b>,93 (.10)</b>	<b>,17 (.09)</b>	0,14 (.08)	0,42 (.22)	,91 (.17)	<b>,18 (.10)</b>	0,15 (.09)	0,45 (.25)
	400	<b>,94 (.06)</b>	<b>,15 (.08)</b>	0,13 (.07)	0,38 (.19)	<b>,93 (.12)</b>	<b>,17 (.09)</b>	0,15 (.08)	0,43 (.22)
	500	<b>,95 (.05)</b>	<b>,14 (.07)</b>	0,12 (.07)	0,35 (.19)	<b>,94 (.06)</b>	<b>,15 (.08)</b>	0,13 (.07)	0,38 (.19)
0,5	200	<b>,95 (.07)</b>	<b>,16 (.07)</b>	0,14 (.07)	0,31 (.15)	<b>,95 (.07)</b>	<b>,17 (.08)</b>	0,15 (.07)	0,34 (.15)
	300	<b>,96 (.04)</b>	<b>,14 (.07)</b>	0,12 (.06)	0,27 (.13)	<b>,96 (.04)</b>	<b>,15 (.07)</b>	0,13 (.06)	0,30 (.14)
	400	<b>,97 (.03)</b>	<b>,12 (.06)</b>	0,11 (.06)	0,24 (.12)	<b>,97 (.04)</b>	<b>,13 (.06)</b>	0,12 (.06)	0,27 (.13)
	500	<b>,98 (.03)</b>	<b>,11 (.05)</b>	<b>,10 (.05)</b>	0,22 (.11)	<b>,97 (.03)</b>	<b>,12 (.06)</b>	0,11 (.06)	0,24 (.12)

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

5 categorías: 5D1 y 5D2 - Caso 1 y 4 (Muthén y Kaplan, 1992).

Dicotómicos: 2D1 y 2D3 – 50%-50% y 75%-25%.

Ficha 15. Niveles heterogéneos de  $\lambda_{ij}$ ,  $n = 4$ **Cuadro 15.1.** Path diagram, notación matricial y condiciones simuladas**Tabla 15.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución x  $N$  x Estimador.

Distribución	$N$	IM ( $\lambda_{ij} (0,15-0,45)$ )		$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0,15-0,45))$		$\hat{\Sigma}_0 (\lambda_{ij} (0,15-0,45))$	
		ML	RDWLS	ML	RDWLS	ML	RDWLS
$\sim N(0,1)$	200	21,1%		24,4%		54,5%	
	300	13,6%		11,3%		75,1%	
	400	7,0%		5,3%		87,7%	
	500	4,2%		2,2%		93,6%	
5 categorías (5D1)	200		21,5%		19,9%		58,6%
	300		14,9%		10,2%		74,9%
	400		10,4%		5,1%		84,5%
	500		6,1%		2,8%		91,1%
5 categorías (5D2)	200		44,5%		6,5%		49,0%
	300		35,6%		4,1%		60,3%
	400		28,4%		3,5%		68,1%
	500		21,6%		2,0%		76,4%
Dicotómica (2D1)	200		39,7%		9,1%		51,2%
	300		29,5%		5,9%		64,6%
	400		24,0%		2,8%		73,2%
	500		17,8%		1,3%		80,9%
Dicotómica (2D3)	200		44,9%		4,3%		50,8%
	300		37,3%		3,5%		59,2%
	400		33,3%		1,6%		65,1%
	500		28,0%		2,4%		69,6%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 15.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ). *Distribución x N x Estimador (Media (D.T.))*

ML	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} (0,15-0,45))$					TI	$\hat{\Sigma}_0 (\lambda_{ij} (0,15-0,45))$			
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>		C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
N(0,1)	200	78,9%	24,4%	,90 (.09)	<b>,14 (.07)</b>	,12 (.06)	,51 (.24)	54,5%	<b>,93 (.06)</b>	<b>,14 (.06)</b>	,12 (.05)	,54 (.26)
	300	86,4%	11,3%	,91 (.08)	<b>,13 (.06)</b>	,12 (.05)	,47 (.22)	75,1%	<b>,94 (.06)</b>	<b>,12 (.06)</b>	<b>,10 (.05)</b>	,46 (.22)
	400	93,0%	5,3%	<b>,93 (.05)</b>	<b>,12 (.04)</b>	<b>,10 (.04)</b>	,40 (.11)	87,7%	<b>,95 (.05)</b>	<b>,11 (.05)</b>	<b>,09 (.04)</b>	,41 (.18)
	500	95,8%	2,2%	<b>,93 (.06)</b>	<b>,12 (.04)</b>	,11 (.04)	,41 (.16)	93,6%	<b>,96 (.04)</b>	<b>,10 (.05)</b>	<b>,08 (.04)</b>	,37 (.16)
RDWLS	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} (0,15-0,45))$					TI	$\hat{\Sigma}_0 (\lambda_{ij} (0,15-0,45))$			
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>		C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
5 cat. (C1)	200	78,5%	19,9%	,83 (.18)	<b>,18 (.09)</b>	,16 (.08)	,71 (.41)	58,6%	,91 (.11)	<b>,16 (.07)</b>	,13 (.06)	,65 (.36)
	300	85,1%	10,2%	,85 (.13)	<b>,17 (.08)</b>	,15 (.07)	,66 (.40)	74,9%	<b>,93 (.07)</b>	<b>,14 (.06)</b>	,11 (.05)	,53 (.26)
	400	89,6%	5,1%	,89 (.10)	<b>,15 (.06)</b>	,13 (.06)	,56 (.33)	84,5%	<b>,94 (.06)</b>	<b>,12 (.06)</b>	<b>,10 (.05)</b>	,46 (.21)
	500	93,9%	2,8%	<b>,93 (.06)</b>	<b>,12 (.04)</b>	<b>,10 (.04)</b>	,42 (.14)	91,1%	<b>,95 (.05)</b>	<b>,11 (.05)</b>	<b>,09 (.04)</b>	,42 (.19)
5 cat. (C4)	200	55,5%	6,5%	,68 (.29)	,24 (.11)	,21 (.10)	1,00 (.64)	49,0%	,82 (.23)	,23 (.10)	,19 (.08)	,99 (.50)
	300	64,4%	4,1%	,69 (.35)	,22 (.12)	,19 (.11)	,92 (.59)	60,3%	,86 (.15)	<b>,19 (.08)</b>	,16 (.07)	,80 (.41)
	400	71,6%	3,5%	,68 (.37)	,23 (.12)	,20 (.11)	,88 (.58)	68,1%	,89 (.12)	<b>,17 (.07)</b>	,14 (.06)	,67 (.33)
	500	78,4%	2,0%	,82 (.17)	<b>,18 (.09)</b>	,16 (.08)	,67 (.37)	76,4%	,91 (.08)	<b>,15 (.06)</b>	,13 (.05)	,59 (.27)
Dicot. (D1)	200	60,3%	9,1%	,74 (.28)	,23 (.10)	,20 (.09)	,90 (.43)	51,2%	,85 (.18)	,21 (.08)	,17 (.07)	,88 (.42)
	300	70,5%	5,9%	,81 (.17)	<b>,19 (.08)</b>	,17 (.08)	,70 (.34)	64,6%	,88 (.12)	<b>,18 (.08)</b>	,15 (.06)	,76 (.39)
	400	76,0%	2,8%	,83 (.15)	<b>,18 (.08)</b>	,16 (.07)	,69 (.43)	73,2%	,90 (.09)	<b>,16 (.07)</b>	,13 (.06)	,65 (.32)
	500	82,2%	1,3%	,83 (.13)	<b>,18 (.07)</b>	,16 (.06)	,67 (.29)	80,9%	,91 (.09)	<b>,15 (.07)</b>	,12 (.06)	,57 (.28)
Dicot. (D3)	200	55,1%	4,3%	,64 (.34)	,26 (.13)	,22 (.11)	1,04 (.62)	50,8%	,80 (.24)	,24 (.10)	,20 (.09)	1,05 (.56)
	300	62,7%	3,5%	,62 (.31)	,26 (.12)	,23 (.11)	1,03 (.61)	59,2%	,84 (.21)	,21 (.10)	,17 (.08)	,88 (.48)
	400	66,7%	1,6%	,54 (.44)	,26 (.11)	,23 (.11)	1,01 (.40)	65,1%	,87 (.16)	<b>,18 (.08)</b>	,15 (.07)	,76 (.41)
	500	72,0%	2,4%	,67 (.38)	,23 (.12)	,20 (.12)	,86 (.54)	69,6%	,89 (.13)	<b>,17 (.07)</b>	,14 (.06)	,66 (.34)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene H<sub>0</sub> del *Modelo de Independencia*; TI - % soluciones en las que se rechaza H<sub>0</sub> del *Modelo de Independencia*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

**Tabla 15.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).

Distribución x N x Estimador (Media (D.T.) sobre soluciones válidas)

ML	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0,15-0,45))$				$\hat{\Sigma}_0 (\lambda_{ij} (0,15-0,45))$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
N(0,1)	200	<b>,98 (,659)</b>	,94 (,12)	<b>1,00 (,13)</b>	,67 (,04)	<b>1,81 (,519)</b>	<b>1,56 (,35)</b>	<b>1,63 (,37)</b>	,88 (,12)
	300	<b>,83 (,703)</b>	,97 (,11)	<b>1,04 (,12)</b>	,67 (,03)	<b>1,78 (,526)</b>	<b>1,75 (,45)</b>	<b>1,83 (,48)</b>	,92 (,15)
	400	<b>,91 (,694)</b>	,98 (,12)	<b>1,05 (,13)</b>	,66 (,03)	<b>1,83 (,512)</b>	<b>2,00 (,51)</b>	<b>2,09 (,55)</b>	,99 (,16)
	500	<b>,52 (,790)</b>	<b>1,03 (,09)</b>	<b>1,13 (,10)</b>	,68 (,03)	<b>1,84 (,520)</b>	<b>2,26 (,62)</b>	<b>2,37 (,66)</b>	<b>1,06 (,19)</b>
RDWLS	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0,15-0,45))$				$\hat{\Sigma}_0 (\lambda_{ij} (0,15-0,45))$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
5 cat. (C1)	200	<b>1,04 (,660)</b>	,93 (,13)	,99 (,13)	,66 (,04)	<b>1,89 (,513)</b>	<b>1,66 (,40)</b>	<b>1,73 (,42)</b>	,92 (,14)
	300	<b>,85 (,696)</b>	,96 (,13)	<b>1,03 (,14)</b>	,66 (,04)	<b>1,86 (,518)</b>	<b>1,86 (,52)</b>	<b>1,94 (,54)</b>	,96 (,17)
	400	<b>,92 (,679)</b>	<b>1,02 (,10)</b>	<b>1,10 (,11)</b>	,68 (,03)	<b>1,83 (,522)</b>	<b>2,10 (,58)</b>	<b>2,20 (,62)</b>	<b>1,02 (,18)</b>
	500	<b>,90 (,684)</b>	<b>1,05 (,05)</b>	<b>1,12 (,07)</b>	,68 (,01)	<b>1,81 (,526)</b>	<b>2,37 (,68)</b>	<b>2,48 (,73)</b>	<b>1,09 (,21)</b>
5 cat. (C4)	200	<b>1,04 (,660)</b>	,93 (,13)	,99 (,13)	,66 (,04)	<b>1,89 (,513)</b>	<b>1,66 (,40)</b>	<b>1,73 (,42)</b>	,92 (,14)
	300	<b>,85 (,696)</b>	,96 (,13)	<b>1,03 (,14)</b>	,66 (,04)	<b>1,86 (,518)</b>	<b>1,86 (,52)</b>	<b>1,94 (,54)</b>	,96 (,17)
	400	<b>,92 (,679)</b>	<b>1,02 (,10)</b>	<b>1,10 (,11)</b>	,68 (,03)	<b>1,83 (,522)</b>	<b>2,10 (,58)</b>	<b>2,20 (,62)</b>	<b>1,02 (,18)</b>
	500	<b>,90 (,684)</b>	<b>1,05 (,05)</b>	<b>1,12 (,07)</b>	,68 (,01)	<b>1,81 (,526)</b>	<b>2,37 (,68)</b>	<b>2,48 (,73)</b>	<b>1,09 (,21)</b>
Dicot. (D1)	200	<b>,63 (,756)</b>	,96 (,11)	<b>1,04 (,12)</b>	,68 (,04)	<b>1,52 (,565)</b>	<b>2,06 (,70)</b>	<b>2,16 (,73)</b>	<b>1,06 (,24)</b>
	300	<b>,55 (,779)</b>	<b>1,00 (,10)</b>	<b>1,09 (,11)</b>	,68 (,03)	<b>1,58 (,554)</b>	<b>2,30 (,79)</b>	<b>2,41 (,84)</b>	<b>1,11 (,26)</b>
	400	<b>,67 (,735)</b>	,96 (,10)	<b>1,04 (,10)</b>	,66 (,03)	<b>1,71 (,542)</b>	<b>2,58 (,93)</b>	<b>2,71 (,97)</b>	<b>1,18 (,30)</b>
	500	<b>,44 (,826)</b>	,99 (,11)	<b>1,08 (,12)</b>	,66 (,03)	<b>1,78 (,525)</b>	<b>2,82 (1,02)</b>	<b>2,95 (1,06)</b>	<b>1,23 (,32)</b>
Dicot. (D3)	200	<b>,39 (,834)</b>	,94 (,15)	<b>1,04 (,17)</b>	,67 (,05)	<b>1,55 (,565)</b>	<b>2,32 (,81)</b>	<b>2,44 (,84)</b>	<b>1,15 (,29)</b>
	300	<b>,35 (,848)</b>	,96 (,10)	<b>1,06 (,12)</b>	,67 (,03)	<b>1,50 (,570)</b>	<b>2,62 (,96)</b>	<b>2,75 (1,00)</b>	<b>1,22 (,32)</b>
	400	<b>,37 (,843)</b>	,91 (,18)	<b>1,00 (,20)</b>	,64 (,05)	<b>1,45 (,574)</b>	<b>2,82 (1,02)</b>	<b>2,97 (1,07)</b>	<b>1,25 (,32)</b>
	500	<b>,41 (,828)</b>	,99 (,13)	<b>1,09 (,14)</b>	,67 (,04)	<b>1,51 (,565)</b>	<b>3,15 (1,14)</b>	<b>3,31 (1,19)</b>	<b>1,33 (,35)</b>

 $\chi^2_0 (p-v)$  - Media (nivel crítico). $ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ :  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

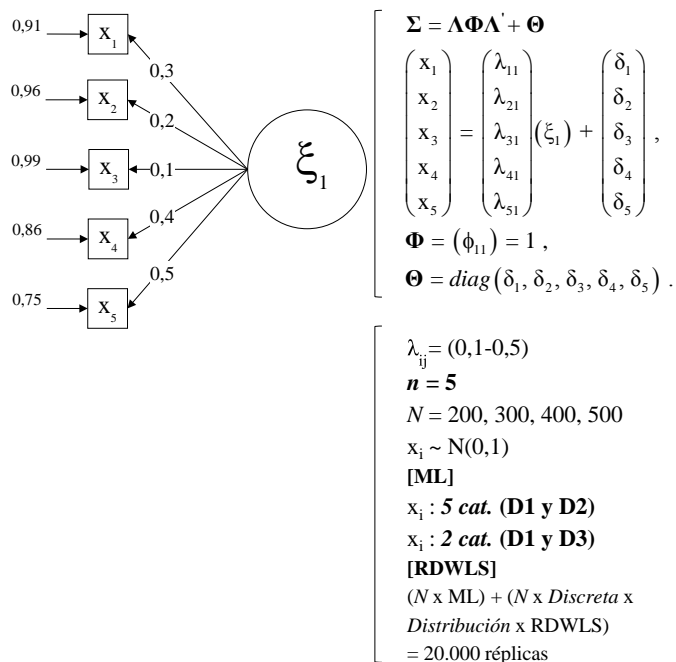
**Tabla 15.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).

*Distribución x N x Estimador (Media (D.T.) sobre soluciones válidas)*

ML	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0,15-0,45))$						$\hat{\Sigma}_0 (\lambda_{ij} (0,15-0,45))$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
N(0,1)	200	<b>,00 (,01)</b>	<b>,02 (,00)</b>	,89 (,08)	1,8 (**)	,67 (,27)	,87 (,31)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,91 (,08)	1,1 (,38)	,73 (,24)	<b>,96 (,07)</b>
	300	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,91 (,08)	2,0 (2,84)	,73 (,24)	,94 (,21)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,92 (,07)	1,1 (,33)	,77 (,22)	<b>,97 (,06)</b>
	400	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,91 (,09)	1,9 (9,69)	,72 (,28)	,91 (,24)	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,93 (,06)	1,1 (,26)	,80 (,19)	<b>,97 (,05)</b>
	500	<b>,00 (,00)</b>	<b>,01 (,00)</b>	,95 (,04)	2,0 (2,99)	,85 (,14)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,94 (,05)	1,1 (,23)	,83 (,17)	<b>,98 (,05)</b>
RDWLS	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0,15-0,45))$						$\hat{\Sigma}_0 (\lambda_{ij} (0,15-0,45))$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
5 cat. (C1)	200	<b>,01 (,02)</b>	<b>,02 (,01)</b>	,89 (,10)	1,8 (**)	,66 (,31)	,82 (,35)	<b>,02 (,03)</b>	<b>,03 (,01)</b>	,92 (,07)	1,1 (,34)	,75 (,22)	<b>,97 (,07)</b>
	300	<b>,00 (,01)</b>	<b>,02 (,00)</b>	,91 (,07)	1,8 (**)	,73 (,22)	,85 (,34)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,93 (,06)	1,1 (,29)	,79 (,20)	<b>,97 (,05)</b>
	400	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,92 (,07)	1,8 (**)	,75 (,21)	<b>,95 (,20)</b>	<b>,01 (,02)</b>	<b>,02 (,01)</b>	,94 (,05)	1,1 (,25)	,82 (,18)	<b>,98 (,05)</b>
	500	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,92 (,06)	1,8 (0,53)	,76 (,20)	<b>,99 (,04)</b>	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,95 (,05)	1,1 (,22)	,84 (,16)	<b>,98 (,04)</b>
5 cat. (C4)	200	<b>,01 (,02)</b>	<b>,02 (,01)</b>	,89 (,10)	1,8 (**)	,66 (,31)	,82 (,35)	<b>,02 (,03)</b>	<b>,03 (,01)</b>	,92 (,07)	1,1 (,34)	,75 (,22)	<b>,97 (,07)</b>
	300	<b>,00 (,01)</b>	<b>,02 (,00)</b>	,91 (,07)	1,8 (**)	,73 (,22)	,85 (,34)	<b>,02 (,03)</b>	<b>,02 (,01)</b>	,93 (,06)	1,1 (,29)	,79 (,20)	<b>,97 (,05)</b>
	400	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,92 (,07)	1,8 (**)	,75 (,21)	<b>,95 (,20)</b>	<b>,01 (,02)</b>	<b>,02 (,01)</b>	,94 (,05)	1,1 (,25)	,82 (,18)	<b>,98 (,05)</b>
	500	<b>,00 (,01)</b>	<b>,01 (,00)</b>	,92 (,06)	1,8 (0,53)	,76 (,20)	<b>,99 (,04)</b>	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,95 (,05)	1,1 (,22)	,84 (,16)	<b>,98 (,04)</b>
Dicot. (D1)	200	<b>,00 (,00)</b>	<b>,02 (,01)</b>	,93 (,05)	2,0 (7,64)	,80 (,17)	,93 (,24)	<b>,01 (,03)</b>	<b>,04 (,01)</b>	,95 (,04)	1,1 (,23)	,85 (,13)	<b>,99 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,94 (,04)	2,1 (**)	,83 (,14)	<b>,96 (,18)</b>	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,95 (,04)	1,1 (,19)	,86 (,12)	<b>,99 (,02)</b>
	400	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,93 (,04)	2,1 (5,71)	,79 (,15)	,93 (,26)	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,96 (,04)	1,1 (,19)	,87 (,12)	<b>,99 (,03)</b>
	500	<b>,00 (,00)</b>	<b>,01 (,00)</b>	,95 (,05)	2,2 (2,88)	,86 (,16)	,91 (,30)	<b>,01 (,02)</b>	<b>,02 (,01)</b>	,96 (,03)	1,1 (,16)	,87 (,11)	<b>,99 (,02)</b>
Dicot. (D3)	200	<b>,00 (,00)</b>	<b>,02 (,01)</b>	,96 (,03)	2,1 (5,05)	,87 (,09)	,83 (,37)	<b>,01 (,03)</b>	<b>,04 (,02)</b>	,96 (,03)	1,1 (,20)	,87 (,10)	<b>,99 (,02)</b>
	300	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,96 (,03)	2,2 (4,04)	,88 (,10)	,94 (,23)	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,96 (,03)	1,1 (,17)	,89 (,10)	<b>,99 (,02)</b>
	400	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,96 (,03)	1,8 (2,31)	,87 (,10)	,69 (,47)	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,97 (,03)	1,1 (,16)	,90 (,09)	<b>,99 (,01)</b>
	500	<b>,00 (,00)</b>	<b>,01 (,00)</b>	,96 (,03)	2,0 (3,40)	,88 (,10)	,91 (,28)	<b>,01 (,02)</b>	<b>,03 (,01)</b>	,97 (,02)	1,1 (,13)	,90 (,08)	<b>,99 (,01)</b>

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

Ficha 16. Niveles heterogéneos de  $\lambda_{ij}$ ,  $n = 5$ **Cuadro 16.1.** Path diagram, notación matricial y condiciones simuladas**Tabla 16.1.** Soluciones impropias,  $\hat{\Sigma}_{\text{Null}}$  y  $\hat{\Sigma}_0$  (%). Distribución x  $N$  x Estimador.

Distribución	$N$	IM ( $\lambda_{ij} (0, 1-0, 5)$ )		$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0, 1-0, 5))$		$\hat{\Sigma}_0 (\lambda_{ij} (0, 1-0, 5))$	
		ML	RDWLS	ML	RDWLS	ML	RDWLS
$\sim N(0, 1)$	200	9,9%		9,4%		80,7%	
	300	3,5%		2,0%		94,5%	
	400	1,7%		0,3%		98,0%	
	500	0,9%		0,0%		99,1%	
5 categorías (5D1)	200		9,8%		7,9%		82,3%
	300		4,0%		1,4%		94,6%
	400		2,2%		0,3%		97,5%
	500		1,4%		0,1%		98,5%
5 categorías (5D2)	200		30,3%		1,6%		68,1%
	300		20,2%		1,2%		78,6%
	400		12,9%		0,2%		86,9%
	500		10,5%		0,2%		89,3%
Dicotómica (2D1)	200		22,7%		2,7%		74,6%
	300		15,1%		1,0%		83,9%
	400		9,5%		0,1%		90,4%
	500		8,1%		0,0%		91,9%
Dicotómica (2D3)	200		34,7%		0,8%		64,5%
	300		24,4%		0,3%		75,3%
	400		17,8%		0,1%		82,1%
	500		13,2%		0,1%		86,7%

IM- Soluciones impropias (no convergentes/casos Heywood).

**Tabla 16.2.** Ajuste teórico en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ). *Distribución x N x Estimador (Media (D.T.))*

ML	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} (0,1-0,5))$					$\hat{\Sigma}_0 (\lambda_{ij} (0,1-0,5))$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
N(0,1)	200	90,1%	9,4%	,91 (.07)	<b>,14 (.05)</b>	,12 (.05)	,51 (.21)	80,7%	<b>,94 (.06)</b>	<b>,12 (.05)</b>	<b>,10 (.04)</b>	,54 (.26)
	300	96,5%	2,0%	<b>,94 (.05)</b>	<b>,12 (.04)</b>	<b>,10 (.03)</b>	,44 (.14)	94,5%	<b>,96 (.04)</b>	<b>,10 (.04)</b>	<b>,08 (.03)</b>	,43 (.19)
	400	98,3%	0,3%	,91 (.12)	<b>,14 (.08)</b>	,12 (.08)	,47 (.23)	98,0%	<b>,97 (.03)</b>	<b>,09 (.04)</b>	<b>,07 (.03)</b>	,39 (.16)
	500	99,1%	0,0%	n.a.	n.a.	n.a.	n.a.	99,1%	<b>,97 (.03)</b>	<b>,08 (.03)</b>	<b>,07 (.03)</b>	,35 (.15)
RDWLS	N	SV	$\hat{\Sigma}_{Null} (\lambda_{ij} (0,1-0,5))$					$\hat{\Sigma}_0 (\lambda_{ij} (0,1-0,5))$				
			T2	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>	T1	C <sub>j</sub>	RMSD <sub>j</sub>	ARB <sub>j</sub>	AMSE <sub>j</sub>
5 cat. (C1)	200	90,2%	7,9%	,82 (.26)	<b>,18 (.09)</b>	,15 (.08)	,75 (.42)	82,3%	,90 (.17)	<b>,15 (.07)</b>	,12 (.06)	,72 (.40)
	300	96,0%	1,4%	,84 (.12)	<b>,18 (.07)</b>	,14 (.05)	,74 (.31)	94,6%	<b>,94 (.07)</b>	<b>,11 (.05)</b>	<b>,09 (.04)</b>	,54 (.26)
	400	97,8%	0,3%	<b>,96 (.02)</b>	<b>,11 (.03)</b>	<b>,10 (.03)</b>	,42 (.11)	97,5%	<b>,96 (.04)</b>	<b>,10 (.04)</b>	<b>,08 (.03)</b>	,47 (.22)
	500	98,6%	0,1%	<b>,99 (.00)</b>	<b>,10 (.00)</b>	<b>,09 (.00)</b>	,54 (.00)	98,5%	<b>,97 (.03)</b>	<b>,09 (.03)</b>	<b>,07 (.03)</b>	,41 (.19)
5 cat. (C4)	200	69,7%	1,6%	,33 (.53)	,33 (.15)	,28 (.12)	1,41 (.71)	68,1%	,76 (.39)	,23 (.13)	,19 (.12)	1,15 (.68)
	300	79,8%	1,2%	,65 (.44)	,23 (.14)	,19 (.13)	1,06 (.90)	78,6%	,83 (.31)	<b>,19 (.11)</b>	,15 (.10)	,90 (.56)
	400	87,1%	0,2%	,86 (.02)	<b>,17 (.01)</b>	,14 (.00)	,76 (.34)	86,9%	,90 (.17)	<b>,15 (.07)</b>	,13 (.06)	,72 (.39)
	500	89,5%	0,2%	<b>,92 (.04)</b>	<b>,16 (.02)</b>	,14 (.01)	,64 (.03)	89,3%	,91 (.18)	<b>,13 (.07)</b>	,11 (.06)	,63 (.34)
Dicot. (D1)	200	77,3%	2,7%	,53 (.58)	,27 (.17)	,23 (.15)	1,19 (.67)	74,6%	,82 (.30)	,20 (.11)	,17 (.09)	1,00 (.58)
	300	84,9%	1,0%	,79 (.22)	,20 (.07)	,17 (.06)	,76 (.37)	83,9%	,88 (.20)	<b>,16 (.08)</b>	,14 (.07)	,79 (.45)
	400	90,5%	0,1%	<b>,95 (.00)</b>	<b>,12 (.00)</b>	<b>,09 (.00)</b>	,33 (.00)	90,4%	,91 (.16)	<b>,14 (.07)</b>	,12 (.06)	,67 (.35)
	500	91,9%	0,0%	n.a.	n.a.	n.a.	n.a.	91,9%	<b>,93 (.12)</b>	<b>,12 (.06)</b>	<b>,10 (.05)</b>	,58 (.28)
Dicot. (D3)	200	65,3%	0,8%	,66 (.25)	,25 (.08)	,22 (.07)	1,22 (.44)	64,5%	,74 (.39)	,24 (.13)	,20 (.11)	1,24 (.69)
	300	75,6%	0,3%	,65 (.23)	,26 (.07)	,22 (.06)	,98 (.28)	75,3%	,82 (.31)	,20 (.11)	,16 (.09)	,96 (.54)
	400	82,2%	0,1%	,86 (.00)	<b>,17 (.00)</b>	,14 (.00)	,47 (.00)	82,1%	,87 (.23)	,17 (.09)	,14 (.08)	,82 (.45)
	500	86,8%	0,1%	,77 (.00)	,21 (.00)	,17 (.00)	,97 (.00)	86,7%	,89 (.19)	,15 (.08)	,13 (.07)	,72 (.39)

SV - % total de soluciones válidas (descontando no soluciones IM). T2 - % soluciones en las que se mantiene  $H_0$  del *Modelo de Independencia*; T1 - % soluciones en las que se rechaza  $H_0$  del *Modelo de Independencia*.

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $C_j \geq 0,92$ ,  $RMSD_j < 0,2$ ,  $ARB_j \leq 0,10$  y  $AMSE_j \leq 0,10$ ).

n.a. – No aplicable.

**Tabla 16.3.**  $\chi^2_0$  e índices alternativos en función del resultado del test  $\chi^2_{Null}$  ( $\alpha = 0,05$ ).

Distribución x N x Estimador (Media (D.T.) sobre soluciones válidas)

ML	N	$\hat{\Sigma}_{Null} (\lambda_{ij} (0,1-0,5))$				$\hat{\Sigma}_0 (\lambda_{ij} (0,1-0,5))$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
N(0,1)	200	<b>3,13 (,682)</b>	,99 (,10)	<b>1,08 (,12)</b>	,70 (,04)	<b>5,02 (,495)</b>	<b>1,65 (,37)</b>	<b>1,74 (,40)</b>	,95 (,14)
	300	<b>2,24 (,798)</b>	,98 (,09)	<b>1,10 (,10)</b>	,69 (,03)	<b>4,91 (,505)</b>	<b>1,98 (,49)</b>	<b>2,09 (,53)</b>	<b>1,05 (,17)</b>
	400	<b>4,15 (,550)</b>	<b>1,08 (,04)</b>	<b>1,14 (,11)</b>	,71 (,02)	<b>4,94 (,504)</b>	<b>2,35 (,57)</b>	<b>2,47 (,62)</b>	<b>1,15 (,19)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>4,84 (,509)</b>	<b>2,74 (,66)</b>	<b>2,89 (,72)</b>	<b>1,26 (,22)</b>
RDWLS	N	$\hat{\Sigma}_{Null} (\lambda_{ij} (0,1-0,5))$				$\hat{\Sigma}_0 (\lambda_{ij} (0,1-0,5))$			
		$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$	$\chi^2_0 (p-v)$	$ECVI_r$	$AIC_r$	$CAIC_r$
5 cat. (C1)	200	<b>3,06 (,699)</b>	<b>1,00 (,11)</b>	<b>1,11 (,13)</b>	,71 (,04)	<b>5,59 (,461)</b>	<b>1,74 (,41)</b>	<b>1,84 (,44)</b>	,99 (,16)
	300	<b>2,56 (,759)</b>	,96 (,12)	<b>1,07 (,14)</b>	,69 (,04)	<b>5,07 (,498)</b>	<b>2,09 (,55)</b>	<b>2,21 (,59)</b>	<b>1,08 (,19)</b>
	400	<b>1,99 (,847)</b>	,96 (,15)	<b>1,09 (,16)</b>	,68 (,05)	<b>5,05 (,505)</b>	<b>2,46 (,63)</b>	<b>2,61 (,69)</b>	<b>1,19 (,22)</b>
	500	<b>3,55 (,616)</b>	<b>1,10 (,00)</b>	<b>1,18 (,00)</b>	,71 (,00)	<b>4,98 (,506)</b>	<b>2,85 (,73)</b>	<b>3,02 (,80)</b>	<b>1,31 (,24)</b>
5 cat. (C4)	200	<b>1,55 (,897)</b>	,93 (,11)	<b>1,09 (,12)</b>	,70 (,04)	<b>4,96 (,509)</b>	<b>2,36 (,74)</b>	<b>2,50 (,76)</b>	<b>1,22 (,28)</b>
	300	<b>1,49 (,904)</b>	<b>1,01 (,07)</b>	<b>1,18 (,08)</b>	,71 (,02)	<b>4,84 (,517)</b>	<b>2,71 (,84)</b>	<b>2,87 (,89)</b>	<b>1,31 (,30)</b>
	400	<b>1,07 (,953)</b>	,97 (,03)	<b>1,16 (,06)</b>	,69 (,01)	<b>4,80 (,521)</b>	<b>3,04 (,96)</b>	<b>3,22 (1,01)</b>	<b>1,39 (,33)</b>
	500	<b>2,31 (,802)</b>	<b>1,01 (,11)</b>	<b>1,14 (,11)</b>	,69 (,03)	<b>4,85 (,514)</b>	<b>3,42 (1,04)</b>	<b>3,61 (1,10)</b>	<b>1,49 (,35)</b>
Dicot. (D1)	200	<b>1,82 (,857)</b>	,99 (,11)	<b>1,14 (,13)</b>	,72 (,04)	<b>4,50 (,553)</b>	<b>2,19 (,62)</b>	<b>2,32 (,63)</b>	<b>1,16 (,23)</b>
	300	<b>1,36 (,912)</b>	,96 (,13)	<b>1,13 (,17)</b>	,70 (,05)	<b>4,63 (,534)</b>	<b>2,58 (,78)</b>	<b>2,74 (,82)</b>	<b>1,26 (,28)</b>
	400	<b>1,18 (,947)</b>	<b>1,00 (,00)</b>	<b>1,18 (,00)</b>	,70 (,00)	<b>4,69 (,528)</b>	<b>2,93 (,87)</b>	<b>3,10 (,93)</b>	<b>1,35 (,30)</b>
	500	n.a.	n.a.	n.a.	n.a.	<b>4,83 (,516)</b>	<b>3,33 (,98)</b>	<b>3,52 (1,05)</b>	<b>1,47 (,33)</b>
Dicot. (D3)	200	<b>1,55 (,894)</b>	,92 (,09)	<b>1,07 (,10)</b>	,69 (,03)	<b>4,51 (,545)</b>	<b>2,57 (,81)</b>	<b>2,72 (,82)</b>	<b>1,30 (,31)</b>
	300	<b>1,10 (,934)</b>	<b>1,07 (,03)</b>	<b>1,28 (,08)</b>	,74 (,02)	<b>4,50 (,547)</b>	<b>2,93 (,94)</b>	<b>3,11 (,98)</b>	<b>1,39 (,34)</b>
	400	<b>,66 (,985)</b>	,88 (,00)	<b>1,06 (,00)</b>	,67 (,00)	<b>4,59 (,540)</b>	<b>3,35 (1,08)</b>	<b>3,55 (1,12)</b>	<b>1,50 (,37)</b>
	500	<b>,75 (,980)</b>	<b>1,00 (,00)</b>	<b>1,21 (,00)</b>	,70 (,00)	<b>4,65 (,531)</b>	<b>3,71 (1,14)</b>	<b>3,93 (1,21)</b>	<b>1,59 (,38)</b>

 $\chi^2_0 (p-v)$  - Media (nivel crítico). $ECVI_r$ ,  $AIC_r$ ,  $CAIC_r$  - Razón entre el valor que toma el índice en el *Modelo de Independencia* y el valor que toma en el *Modelo Evaluado*.Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $\chi^2_0$ :  $p \geq 0,05$ ) y las celdas en las que el valor  $ECVI$ ,  $AIC$  o  $CAIC$  del modelo nulo es mayor que el del modelo evaluado (razón  $> 1$ ).

n.a. - No aplicable.



**Tabla 16.4.** Índices de ajuste descriptivo en función del resultado del test  $\chi^2_{\text{Null}}$  ( $\alpha = 0,05$ ).

*Distribución x N x Estimador (Media (D.T.) sobre soluciones válidas)*

ML	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0,1-0,5))$						$\hat{\Sigma}_0 (\lambda_{ij} (0,1-0,5))$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
N(0,1)	200	<b>,00 (,01)</b>	<b>,03 (,00)</b>	,79 (,10)	1,72 (2,37)	,58 (,21)	,94 (,19)	<b>,02 (,03)</b>	<b>,04 (,01)</b>	,84 (,09)	1,05 (,30)	,69 (,18)	<b>,95 (,08)</b>
	300	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,84 (,08)	2,29 (**)	,69 (,17)	<b>1,0 (,00)</b>	<b>,02 (,02)</b>	<b>,03 (,00)</b>	,88 (,07)	1,05 (,22)	,75 (,15)	<b>,96 (,06)</b>
	400	<b>,01 (,01)</b>	<b>,02 (,00)</b>	,76 (,11)	1,33 (,49)	,52 (,22)	<b>,95 (,08)</b>	<b>,01 (,02)</b>	<b>,03 (,00)</b>	,90 (,06)	1,03 (,17)	,80 (,13)	<b>,97 (,05)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,02 (,00)</b>	,92 (,05)	1,03 (,13)	,83 (,11)	<b>,98 (,04)</b>
RDWLS	N	$\hat{\Sigma}_{\text{Null}} (\lambda_{ij} (0,1-0,5))$						$\hat{\Sigma}_0 (\lambda_{ij} (0,1-0,5))$					
		RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI	RMSEA	SRMR	NFI	NNFI <sup>(a)</sup>	RFI	CFI
5 cat. (C1)	200	<b>,00 (,01)</b>	<b>,03 (,00)</b>	,81 (,09)	1,73 (**)	,63 (,18)	,90 (,28)	<b>,02 (,03)</b>	<b>,04 (,01)</b>	,85 (,08)	1,05 (,28)	,70 (,18)	<b>,95 (,08)</b>
	300	<b>,00 (,01)</b>	<b>,02 (,00)</b>	,82 (,09)	1,98 (2,25)	,65 (,19)	,85 (,36)	<b>,02 (,02)</b>	<b>,03 (,01)</b>	,89 (,07)	1,05 (,21)	,77 (,14)	<b>,97 (,06)</b>
	400	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,86 (,03)	1,79 (8,30)	,71 (,07)	,67 (,57)	<b>,01 (,02)</b>	<b>,03 (,00)</b>	,91 (,06)	1,04 (,16)	,81 (,12)	<b>,98 (,04)</b>
	500	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,81 (,00)	1,47 (,00)	,63 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,03 (,00)</b>	,92 (,05)	1,03 (,13)	,84 (,10)	<b>,98 (,03)</b>
5 cat. (C4)	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,89 (,04)	2,39 (**)	,79 (,08)	,88 (,34)	<b>,02 (,02)</b>	<b>,06 (,01)</b>	,91 (,04)	1,05 (,18)	,82 (,09)	<b>,98 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,90 (,04)	2,34 (2,02)	,81 (,08)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,92 (,04)	1,04 (,15)	,85 (,08)	<b>,99 (,02)</b>
	400	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,93 (,03)	2,87 (,14)	,86 (,07)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,93 (,03)	1,04 (,12)	,86 (,08)	<b>,99 (,02)</b>
	500	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,86 (,00)	2,27 (,82)	,72 (,01)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,94 (,03)	1,03 (,10)	,88 (,07)	<b>,99 (,02)</b>
Dicot. (D1)	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,88 (,05)	2,01 (**)	,77 (,11)	,93 (,26)	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,91 (,04)	1,08 (,19)	,81 (,10)	<b>,99 (,03)</b>
	300	<b>,00 (,00)</b>	<b>,03 (,00)</b>	,90 (,06)	2,09 (6,40)	,80 (,13)	,80 (,42)	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,92 (,04)	1,05 (,15)	,84 (,09)	<b>,98 (,03)</b>
	400	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,93 (,00)	2,59 (,00)	,85 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,93 (,04)	1,04 (,13)	,86 (,08)	<b>,99 (,02)</b>
	500	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,94 (,03)	1,03 (,11)	,87 (,08)	<b>,99 (,02)</b>
Dicot. (D3)	200	<b>,00 (,00)</b>	<b>,04 (,00)</b>	,89 (,04)	2,49 (3,41)	,78 (,08)	,88 (,35)	<b>,01 (,02)</b>	<b>,06 (,01)</b>	,92 (,03)	1,06 (,15)	,85 (,08)	<b>,99 (,02)</b>
	300	<b>,00 (,00)</b>	<b>,03 (,01)</b>	,94 (,05)	2,14 (,19)	,88 (,10)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,93 (,03)	1,04 (,14)	,87 (,07)	<b>,99 (,02)</b>
	400	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,94 (,00)	5,22 (,00)	,88 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,05 (,01)</b>	,94 (,03)	1,03 (,11)	,88 (,07)	<b>,99 (,02)</b>
	500	<b>,00 (,00)</b>	<b>,02 (,00)</b>	,95 (,00)	2,69 (,00)	,90 (,00)	<b>1,0 (,00)</b>	<b>,01 (,02)</b>	<b>,04 (,01)</b>	,94 (,03)	1,03 (,10)	,89 (,06)	<b>,99 (,02)</b>

Se resaltan las celdas con valores que cumplen criterios / recomendaciones ( $RMSEA \leq 0,05$ ,  $SRMR \leq 0,08$ ,  $0,95 < NNFI < 1$ ,  $CFI \geq 0,95$ ).

<sup>(a)</sup> Presencia de valores extremos fuera de rango (se utiliza la mediana en lugar de la media). \*\* - D.T. > 10.

n.a. – No aplicable.

## F. Promedio de las cargas factoriales estimadas

Valores promedio (desviación típica entre paréntesis) de los parámetros estimados. Se muestran las soluciones para modelos compuestos por 4, 5 y 6 variables observables observables).

### F.1. Datos continuos (estimación ML)

Test $\chi^2_{\text{Null}}$	$\lambda_{ij}$	$N$	Variables observables ( $n = 4$ )			
			$x_1$	$x_2$	$x_3$	$x_4$
<i>H<sub>0</sub> modelo independ.</i>	0,2	200	0,268 (0,17)	0,166 (0,25)	0,171 (0,26)	0,179 (0,26)
		300	0,243 (0,15)	0,192 (0,22)	0,188 (0,21)	0,185 (0,21)
		400	0,238 (0,16)	0,189 (0,20)	0,182 (0,20)	0,188 (0,20)
		500	0,236 (0,17)	0,202 (0,18)	0,180 (0,18)	0,177 (0,17)
	0,3	200	0,276 (0,15)	0,258 (0,20)	0,268 (0,18)	0,264 (0,18)
		300	0,261 (0,15)	0,265 (0,16)	0,250 (0,14)	0,255 (0,17)
		400	0,239 (0,11)	0,256 (0,16)	0,229 (0,11)	0,254 (0,12)
		500	0,260 (0,12)	0,218 (0,13)	0,230 (0,10)	0,247 (0,11)
	0,4	200	0,354 (0,15)	0,315 (0,16)	0,327 (0,12)	0,338 (0,19)
		300	0,408 (0,14)	0,302 (0,04)	0,456 (0,12)	0,303 (0,14)
		400	0,371 (0,10)	0,396 (0,04)	0,350 (0,08)	0,372 (0,08)
		500	0,425 (0,07)	0,422 (0,08)	0,294 (0,02)	0,397 (0,05)
<i>H<sub>1</sub> modelo independ.</i>	0,2	200	0,328 (0,16)	0,250 (0,29)	0,287 (0,23)	0,267 (0,25)
		300	0,288 (0,18)	0,274 (0,22)	0,263 (0,19)	0,281 (0,20)
		400	0,294 (0,17)	0,249 (0,17)	0,267 (0,16)	0,287 (0,16)
		500	0,282 (0,16)	0,245 (0,16)	0,249 (0,15)	0,262 (0,16)
	0,3	200	0,350 (0,16)	0,339 (0,16)	0,336 (0,17)	0,349 (0,16)
		300	0,325 (0,14)	0,316 (0,13)	0,321 (0,13)	0,332 (0,13)
		400	0,317 (0,12)	0,308 (0,12)	0,312 (0,11)	0,320 (0,12)
		500	0,311 (0,11)	0,305 (0,10)	0,306 (0,10)	0,313 (0,11)
	0,4	200	0,404 (0,12)	0,402 (0,12)	0,404 (0,12)	0,408 (0,12)
		300	0,404 (0,10)	0,397 (0,10)	0,401 (0,10)	0,408 (0,10)
		400	0,402 (0,08)	0,398 (0,09)	0,403 (0,08)	0,408 (0,08)
		500	0,403 (0,08)	0,400 (0,07)	0,402 (0,07)	0,405 (0,07)

Test $\chi^2_{\text{Null}}$	$\lambda_{ij}$	$N$	Variables observables ( $n = 5$ )				
			$x_1$	$x_2$	$x_3$	$x_4$	$x_5$
<i>H<sub>0</sub> modelo independ.</i>	0,2	200	0,256 (0,17)	0,151 (0,26)	0,157 (0,24)	0,164 (0,27)	0,142 (0,22)
		300	0,251 (0,18)	0,163 (0,20)	0,187 (0,22)	0,165 (0,19)	0,172 (0,20)
		400	0,232 (0,15)	0,167 (0,20)	0,165 (0,16)	0,176 (0,18)	0,174 (0,18)
		500	0,209 (0,13)	0,176 (0,17)	0,174 (0,15)	0,177 (0,16)	0,173 (0,16)
	0,3	200	0,274 (0,16)	0,233 (0,19)	0,223 (0,15)	0,253 (0,18)	0,255 (0,17)
		300	0,257 (0,11)	0,237 (0,13)	0,239 (0,13)	0,258 (0,14)	0,210 (0,13)
		400	0,260 (0,11)	0,182 (0,11)	0,182 (0,17)	0,229 (0,12)	0,182 (0,15)
		500	0,234 (0,08)	0,273 (0,22)	0,167 (0,11)	0,195 (0,14)	0,210 (0,06)
	0,4	200	0,309 (0,03)	0,235 (0,11)	0,299 (0,02)	0,327 (0,14)	0,225 (0,08)
		300	---	---	---	---	---
		400	---	---	---	---	---
		500	---	---	---	---	---
<i>H<sub>1</sub> modelo independ.</i>	0,2	200	0,303 (0,20)	0,221 (0,26)	0,214 (0,26)	0,212 (0,24)	0,224 (0,27)
		300	0,275 (0,17)	0,245 (0,16)	0,245 (0,19)	0,255 (0,17)	0,247 (0,19)
		400	0,260 (0,15)	0,227 (0,16)	0,246 (0,17)	0,221 (0,17)	0,231 (0,16)
		500	0,255 (0,12)	0,231 (0,14)	0,242 (0,15)	0,234 (0,13)	0,226 (0,12)
	0,3	200	0,325 (0,14)	0,315 (0,15)	0,320 (0,16)	0,320 (0,15)	0,309 (0,15)
		300	0,314 (0,11)	0,301 (0,12)	0,310 (0,12)	0,309 (0,12)	0,310 (0,11)
		400	0,306 (0,10)	0,299 (0,10)	0,304 (0,10)	0,306 (0,10)	0,305 (0,10)
		500	0,305 (0,09)	0,298 (0,09)	0,301 (0,09)	0,304 (0,09)	0,303 (0,09)
	0,4	200	0,402 (0,11)	0,401 (0,10)	0,401 (0,11)	0,402 (0,10)	0,398 (0,10)
		300	0,404 (0,08)	0,397 (0,08)	0,402 (0,08)	0,403 (0,08)	0,401 (0,08)
		400	0,402 (0,07)	0,397 (0,07)	0,401 (0,07)	0,402 (0,07)	0,402 (0,07)
		500	0,403 (0,06)	0,397 (0,06)	0,400 (0,07)	0,402 (0,06)	0,402 (0,06)

Test $\chi^2_{\text{Null}}$	$\lambda_{ij}$	$N$	<i>Variables observables (n = 6)</i>					
			$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
<i>H<sub>0</sub> modelo independ.</i>	0,2	200	0,234 (0,17)	0,143 (0,25)	0,138 (0,24)	0,139 (0,24)	0,119 (0,23)	0,148 (0,24)
		300	0,219 (0,14)	0,172 (0,20)	0,151 (0,20)	0,145 (0,21)	0,149 (0,19)	0,165 (0,19)
		400	0,206 (0,14)	0,169 (0,18)	0,166 (0,16)	0,161 (0,17)	0,159 (0,17)	0,163 (0,18)
		500	0,191 (0,12)	0,182 (0,16)	0,161 (0,14)	0,163 (0,16)	0,159 (0,16)	0,181 (0,14)
	0,3	200	0,231 (0,12)	0,252 (0,16)	0,211 (0,17)	0,252 (0,20)	0,222 (0,16)	0,245 (0,17)
		300	0,253 (0,15)	0,206 (0,10)	0,232 (0,12)	0,237 (0,10)	0,220 (0,11)	0,240 (0,11)
		400	0,191 (0,11)	0,251 (0,08)	0,211 (0,08)	0,222 (0,11)	0,239 (0,09)	0,225 (0,09)
		500	---	---	---	---	---	---
	0,4	200	---	---	---	---	---	---
		300	---	---	---	---	---	---
		400	---	---	---	---	---	---
		500	---	---	---	---	---	---
<i>H<sub>1</sub> modelo independ.</i>	0,2	200	0,246 (0,16)	0,215 (0,23)	0,197 (0,26)	0,217 (0,24)	0,235 (0,25)	0,221 (0,23)
		300	0,247 (0,15)	0,194 (0,19)	0,214 (0,17)	0,224 (0,20)	0,235 (0,20)	0,214 (0,19)
		400	0,234 (0,13)	0,221 (0,16)	0,212 (0,16)	0,214 (0,16)	0,218 (0,17)	0,205 (0,16)
		500	0,235 (0,12)	0,213 (0,16)	0,206 (0,14)	0,211 (0,16)	0,217 (0,14)	0,210 (0,14)
	0,3	200	0,309 (0,13)	0,314 (0,14)	0,303 (0,13)	0,312 (0,14)	0,309 (0,13)	0,313 (0,14)
		300	0,298 (0,11)	0,305 (0,11)	0,300 (0,11)	0,305 (0,11)	0,302 (0,11)	0,307 (0,11)
		400	0,297 (0,09)	0,304 (0,09)	0,300 (0,09)	0,303 (0,09)	0,299 (0,09)	0,307 (0,09)
		500	0,295 (0,08)	0,305 (0,08)	0,301 (0,08)	0,303 (0,08)	0,301 (0,08)	0,305 (0,08)
	0,4	200	0,396 (0,10)	0,402 (0,10)	0,395 (0,10)	0,402 (0,10)	0,400 (0,09)	0,403 (0,10)
		300	0,396 (0,08)	0,402 (0,08)	0,398 (0,08)	0,402 (0,08)	0,400 (0,07)	0,404 (0,08)
		400	0,396 (0,07)	0,403 (0,07)	0,400 (0,07)	0,402 (0,07)	0,399 (0,07)	0,404 (0,07)
		500	0,396 (0,06)	0,403 (0,06)	0,401 (0,06)	0,403 (0,06)	0,401 (0,06)	0,403 (0,06)

F.2. Datos ordinales – 5 categorías ( $\lambda_{ij} = 0,3$ ; estimación RDWLS)

Test $\chi^2_{\text{Null}}$	Distrib.	N	Variables observables (n = 4)			
			$x_1$	$x_2$	$x_3$	$x_4$
$H_0$ modelo independ.	5D1	200	0,276 (0,16)	0,227 (0,19)	0,258 (0,24)	0,230 (0,22)
		300	0,286 (0,19)	0,241 (0,19)	0,230 (0,19)	0,229 (0,18)
		400	0,249 (0,11)	0,239 (0,12)	0,224 (0,11)	0,251 (0,17)
		500	0,252 (0,11)	0,211 (0,12)	0,252 (0,11)	0,228 (0,12)
	5D2	200	0,309 (0,19)	0,192 (0,33)	0,198 (0,32)	0,182 (0,35)
		300	0,318 (0,20)	0,251 (0,25)	0,189 (0,27)	0,247 (0,23)
		400	0,269 (0,18)	0,251 (0,18)	0,270 (0,22)	0,261 (0,22)
		500	0,285 (0,18)	0,141 (0,23)	0,299 (0,26)	0,211 (0,23)
	5D3	200	0,283 (0,17)	0,244 (0,22)	0,266 (0,22)	0,252 (0,19)
		300	0,263 (0,14)	0,256 (0,17)	0,258 (0,20)	0,263 (0,19)
		400	0,290 (0,19)	0,238 (0,14)	0,239 (0,24)	0,216 (0,15)
		500	0,291 (0,15)	0,232 (0,11)	0,266 (0,12)	0,239 (0,12)
$H_1$ modelo independ.	5D1	200	0,355 (0,17)	0,338 (0,18)	0,341 (0,18)	0,346 (0,17)
		300	0,330 (0,15)	0,318 (0,15)	0,326 (0,15)	0,331 (0,15)
		400	0,325 (0,14)	0,307 (0,14)	0,315 (0,13)	0,320 (0,13)
		500	0,317 (0,13)	0,300 (0,12)	0,308 (0,13)	0,313 (0,13)
	5D2	200	0,367 (0,20)	0,340 (0,29)	0,317 (0,28)	0,323 (0,26)
		300	0,347 (0,18)	0,302 (0,23)	0,324 (0,23)	0,324 (0,24)
		400	0,325 (0,18)	0,304 (0,22)	0,323 (0,22)	0,312 (0,21)
		500	0,325 (0,17)	0,311 (0,18)	0,327 (0,19)	0,309 (0,18)
	5D3	200	0,338 (0,16)	0,334 (0,18)	0,347 (0,19)	0,345 (0,18)
		300	0,324 (0,15)	0,317 (0,15)	0,321 (0,15)	0,336 (0,15)
		400	0,319 (0,13)	0,312 (0,14)	0,316 (0,13)	0,321 (0,13)
		500	0,314 (0,12)	0,309 (0,12)	0,304 (0,12)	0,314 (0,12)

Test $\chi^2_{\text{Null}}$	Distrib.	N	Variables observables (n = 5)				
			$x_1$	$x_2$	$x_3$	$x_4$	$x_5$
<i>H<sub>0</sub> modelo independ.</i>	5D1	200	0,268 (0,18)	0,230 (0,21)	0,221 (0,16)	0,261 (0,19)	0,226 (0,23)
		300	0,254 (0,16)	0,231 (0,18)	0,243 (0,17)	0,248 (0,15)	0,179 (0,12)
		400	0,243 (0,09)	0,206 (0,18)	0,196 (0,10)	0,224 (0,11)	0,244 (0,11)
		500	0,223 (0,08)	0,156 (0,08)	0,224 (0,14)	0,269 (0,10)	0,179 (0,09)
	5D2	200	0,283 (0,20)	0,146 (0,36)	0,160 (0,31)	0,159 (0,34)	0,096 (0,35)
		300	0,253 (0,20)	0,181 (0,26)	0,249 (0,33)	0,202 (0,22)	0,173 (0,26)
		400	0,229 (0,15)	0,096 (0,23)	0,252 (0,30)	0,214 (0,21)	0,113 (0,31)
		500	0,141 (0,10)	-0,109 (0,38)	0,206 (0,45)	0,103 (0,18)	0,125 (0,19)
	5D3	200	0,280 (0,17)	0,222 (0,19)	0,239 (0,19)	0,283 (0,19)	0,236 (0,18)
		300	0,289 (0,12)	0,230 (0,12)	0,265 (0,12)	0,271 (0,13)	0,203 (0,11)
		400	0,258 (0,12)	0,172 (0,17)	0,199 (0,19)	0,260 (0,18)	0,174 (0,20)
		500	0,264 (0,10)	0,255 (0,14)	0,296 (0,11)	0,168 (0,13)	0,165 (0,11)
<i>H<sub>1</sub> modelo independ.</i>	5D1	200	0,321 (0,15)	0,308 (0,19)	0,321 (0,18)	0,313 (0,18)	0,307 (0,17)
		300	0,316 (0,13)	0,301 (0,13)	0,315 (0,13)	0,309 (0,13)	0,311 (0,13)
		400	0,307 (0,11)	0,297 (0,11)	0,310 (0,12)	0,306 (0,11)	0,305 (0,12)
		500	0,307 (0,10)	0,296 (0,10)	0,304 (0,10)	0,306 (0,10)	0,306 (0,10)
	5D2	200	0,337 (0,19)	0,276 (0,27)	0,297 (0,27)	0,291 (0,28)	0,295 (0,27)
		300	0,321 (0,18)	0,280 (0,21)	0,298 (0,24)	0,300 (0,23)	0,295 (0,23)
		400	0,302 (0,16)	0,285 (0,20)	0,302 (0,20)	0,299 (0,21)	0,288 (0,20)
		500	0,309 (0,15)	0,293 (0,15)	0,309 (0,17)	0,305 (0,17)	0,298 (0,17)
	5D3	200	0,319 (0,16)	0,306 (0,18)	0,304 (0,18)	0,305 (0,19)	0,304 (0,18)
		300	0,313 (0,13)	0,304 (0,13)	0,308 (0,13)	0,305 (0,13)	0,312 (0,13)
		400	0,307 (0,11)	0,302 (0,11)	0,301 (0,11)	0,306 (0,11)	0,308 (0,11)
		500	0,305 (0,10)	0,300 (0,10)	0,298 (0,10)	0,305 (0,10)	0,304 (0,10)

Test $\chi^2_{\text{Null}}$	Distrib.	N	Variables observables (n = 6)					
			$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
$H_0$ modelo independ.	5D1	200	0,234 (0,16)	0,221 (0,19)	0,184 (0,22)	0,209 (0,20)	0,205 (0,17)	0,248 (0,18)
		300	0,276 (0,23)	0,179 (0,11)	0,214 (0,09)	0,180 (0,12)	0,241 (0,19)	0,274 (0,18)
		400	0,275 (0,15)	0,194 (0,08)	0,176 (0,06)	0,231 (0,15)	0,185 (0,17)	0,211 (0,10)
		500	---	---	---	---	---	---
	5D2	200	0,292 (0,21)	0,178 (0,32)	0,192 (0,31)	0,186 (0,28)	0,175 (0,26)	0,141 (0,24)
		300	0,235 (0,17)	0,124 (0,16)	0,053 (0,30)	0,181 (0,35)	0,292 (0,25)	0,232 (0,26)
		400	0,282 (0,17)	-0,015 (0,22)	0,050 (0,25)	0,174 (0,12)	0,274 (0,56)	0,160 (0,10)
		500	---	---	---	---	---	---
	5D3	200	0,254 (0,16)	0,244 (0,20)	0,214 (0,18)	0,239 (0,19)	0,230 (0,17)	0,225 (0,17)
		300	0,234 (0,12)	0,154 (0,08)	0,260 (0,16)	0,229 (0,16)	0,266 (0,16)	0,267 (0,19)
		400	0,246 (0,08)	0,281 (0,11)	0,206 (0,09)	0,241 (0,12)	0,270 (0,14)	0,202 (0,08)
		500	---	---	---	---	---	---
$H_1$ modelo independ.	5D1	200	0,311 (0,15)	0,306 (0,15)	0,295 (0,16)	0,310 (0,16)	0,305 (0,16)	0,308 (0,16)
		300	0,302 (0,12)	0,303 (0,12)	0,297 (0,12)	0,308 (0,13)	0,303 (0,12)	0,308 (0,13)
		400	0,298 (0,10)	0,304 (0,10)	0,302 (0,10)	0,305 (0,10)	0,301 (0,10)	0,308 (0,10)
		500	0,295 (0,09)	0,305 (0,09)	0,304 (0,09)	0,307 (0,09)	0,302 (0,09)	0,306 (0,09)
	5D2	200	0,330 (0,20)	0,261 (0,27)	0,252 (0,27)	0,272 (0,27)	0,268 (0,25)	0,270 (0,27)
		300	0,307 (0,17)	0,282 (0,21)	0,284 (0,21)	0,295 (0,22)	0,286 (0,21)	0,287 (0,21)
		400	0,306 (0,15)	0,287 (0,18)	0,287 (0,18)	0,292 (0,18)	0,291 (0,18)	0,293 (0,18)
		500	0,302 (0,13)	0,288 (0,16)	0,293 (0,16)	0,295 (0,17)	0,293 (0,15)	0,298 (0,15)
	5D3	200	0,306 (0,14)	0,307 (0,17)	0,293 (0,15)	0,309 (0,16)	0,304 (0,15)	0,309 (0,16)
		300	0,299 (0,12)	0,307 (0,13)	0,297 (0,13)	0,305 (0,13)	0,301 (0,12)	0,306 (0,12)
		400	0,294 (0,10)	0,305 (0,11)	0,300 (0,10)	0,303 (0,10)	0,301 (0,10)	0,306 (0,11)
		500	0,294 (0,09)	0,307 (0,09)	0,301 (0,09)	0,304 (0,09)	0,302 (0,09)	0,305 (0,09)

F.3. Datos dicotómicos ( $\lambda_{ij} = 0,3$ ; estimación RDWLS)

Test $\chi^2_{\text{Null}}$	Distrib.	N	Variables observables (n = 4)			
			$x_1$	$x_2$	$x_3$	$x_4$
$H_0$ modelo independ.	2D1	200	0,295 (0,20)	0,199 (0,27)	0,207 (0,29)	0,204 (0,26)
		300	0,301 (0,20)	0,214 (0,23)	0,182 (0,24)	0,194 (0,24)
		400	0,248 (0,15)	0,241 (0,18)	0,157 (0,19)	0,211 (0,15)
		500	0,194 (0,10)	0,272 (0,23)	0,172 (0,14)	0,250 (0,14)
	2D2	200	0,313 (0,22)	0,224 (0,30)	0,203 (0,31)	0,206 (0,28)
		300	0,283 (0,18)	0,257 (0,25)	0,265 (0,24)	0,249 (0,23)
		400	0,290 (0,24)	0,255 (0,21)	0,275 (0,25)	0,199 (0,22)
		500	0,215 (0,14)	0,300 (0,31)	0,166 (0,19)	0,240 (0,25)
	2D3	200	0,344 (0,23)	0,243 (0,37)	0,181 (0,32)	0,209 (0,35)
		300	0,387 (0,23)	0,210 (0,29)	0,226 (0,28)	0,238 (0,29)
		400	0,331 (0,21)	0,278 (0,28)	0,274 (0,25)	0,193 (0,29)
		500	0,300 (0,16)	0,238 (0,32)	0,180 (0,27)	0,183 (0,32)
$H_1$ modelo independ.	2D1	200	0,375 (0,20)	0,337 (0,23)	0,335 (0,26)	0,318 (0,26)
		300	0,345 (0,18)	0,328 (0,21)	0,328 (0,21)	0,333 (0,21)
		400	0,331 (0,16)	0,322 (0,18)	0,325 (0,18)	0,318 (0,19)
		500	0,324 (0,16)	0,313 (0,17)	0,323 (0,18)	0,317 (0,17)
	2D2	200	0,368 (0,19)	0,328 (0,24)	0,321 (0,26)	0,324 (0,25)
		300	0,344 (0,19)	0,306 (0,22)	0,312 (0,24)	0,330 (0,24)
		400	0,330 (0,16)	0,313 (0,20)	0,324 (0,19)	0,324 (0,19)
		500	0,332 (0,17)	0,307 (0,17)	0,319 (0,17)	0,322 (0,17)
	2D3	200	0,384 (0,21)	0,276 (0,30)	0,309 (0,30)	0,298 (0,29)
		300	0,366 (0,20)	0,291 (0,27)	0,299 (0,26)	0,304 (0,26)
		400	0,346 (0,18)	0,295 (0,24)	0,301 (0,22)	0,313 (0,23)
		500	0,346 (0,18)	0,302 (0,20)	0,303 (0,20)	0,308 (0,22)



Test $\chi^2_{\text{Null}}$	Distrib.	N	Variables observables (n = 5)				
			$x_1$	$x_2$	$x_3$	$x_4$	$x_5$
<i>H<sub>0</sub> modelo independ.</i>	2D1	200	0,311 (0,23)	0,165 (0,29)	0,114 (0,28)	0,153 (0,26)	0,181 (0,18)
		300	0,275 (0,17)	0,189 (0,20)	0,258 (0,26)	0,192 (0,19)	0,159 (0,15)
		400	0,305 (0,16)	0,125 (0,14)	0,157 (0,29)	0,116 (0,12)	0,204 (0,19)
		500	0,292 (0,11)	0,080 (0,11)	0,178 (0,13)	0,208 (0,17)	0,187 (0,28)
	2D2	200	0,278 (0,20)	0,111 (0,31)	0,050 (0,30)	0,179 (0,37)	0,163 (0,29)
		300	0,292 (0,16)	0,184 (0,26)	0,186 (0,17)	0,243 (0,31)	0,203 (0,24)
		400	0,300 (0,17)	0,190 (0,28)	0,158 (0,18)	0,161 (0,33)	0,228 (0,23)
		500	0,252 (0,08)	0,124 (0,13)	0,269 (0,12)	0,310 (0,21)	0,234 (0,13)
	2D3	200	0,293 (0,21)	0,225 (0,33)	0,174 (0,30)	0,242 (0,34)	0,265 (0,31)
		300	0,301 (0,18)	0,231 (0,29)	0,234 (0,22)	0,277 (0,32)	0,253 (0,26)
		400	0,344 (0,18)	0,218 (0,19)	0,295 (0,26)	0,313 (0,24)	0,247 (0,17)
		500	0,290 (0,10)	0,184 (0,18)	0,357 (0,25)	0,278 (0,19)	0,216 (0,17)
<i>H<sub>1</sub> modelo independ.</i>	2D1	200	0,348 (0,19)	0,305 (0,26)	0,286 (0,25)	0,287 (0,25)	0,307 (0,24)
		300	0,322 (0,17)	0,294 (0,21)	0,295 (0,21)	0,298 (0,21)	0,303 (0,21)
		400	0,312 (0,15)	0,297 (0,18)	0,293 (0,18)	0,303 (0,19)	0,303 (0,18)
		500	0,308 (0,14)	0,301 (0,15)	0,301 (0,16)	0,303 (0,15)	0,304 (0,14)
	2D2	200	0,358 (0,20)	0,304 (0,24)	0,296 (0,25)	0,297 (0,25)	0,291 (0,24)
		300	0,334 (0,18)	0,302 (0,20)	0,311 (0,20)	0,298 (0,20)	0,314 (0,20)
		400	0,313 (0,16)	0,294 (0,18)	0,297 (0,18)	0,305 (0,19)	0,306 (0,17)
		500	0,310 (0,14)	0,301 (0,15)	0,303 (0,16)	0,306 (0,16)	0,300 (0,15)
	2D3	200	0,359 (0,21)	0,241 (0,32)	0,271 (0,29)	0,267 (0,32)	0,267 (0,28)
		300	0,330 (0,20)	0,270 (0,25)	0,283 (0,26)	0,279 (0,25)	0,292 (0,25)
		400	0,324 (0,17)	0,284 (0,21)	0,292 (0,21)	0,299 (0,22)	0,305 (0,21)
		500	0,321 (0,16)	0,295 (0,18)	0,290 (0,18)	0,309 (0,19)	0,307 (0,17)

Test $\chi^2_{\text{Null}}$	Distrib.	N	Variables observables (n = 6)					
			$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
<i>H<sub>0</sub> modelo independ.</i>	2D1	200	0,343 (0,29)	0,097 (0,23)	0,151 (0,24)	0,099 (0,23)	0,148 (0,12)	0,198 (0,36)
		300	0,197 (0,20)	0,086 (0,23)	0,046 (0,34)	-0,133 (0,45)	0,013 (0,22)	0,054 (0,13)
		400	---	---	---	---	---	---
		500	---	---	---	---	---	---
	2D2	200	0,358 (0,21)	0,123 (0,26)	0,115 (0,27)	0,179 (0,19)	0,249 (0,29)	0,277 (0,26)
		300	0,152 (0,22)	0,214 (0,39)	0,213 (0,26)	0,238 (0,33)	0,186 (0,16)	0,168 (0,12)
		400	---	---	---	---	---	---
		500	---	---	---	---	---	---
	2D3	200	0,421 (0,25)	0,187 (0,31)	0,270 (0,27)	0,264 (0,16)	0,186 (0,28)	0,200 (0,32)
		300	0,278 (0,15)	0,202 (0,22)	0,219 (0,28)	0,211 (0,25)	0,187 (0,49)	0,257 (0,15)
		400	---	---	---	---	---	---
		500	---	---	---	---	---	---
<i>H<sub>1</sub> modelo independ.</i>	2D1	200	0,308 (0,18)	0,280 (0,27)	0,273 (0,24)	0,278 (0,25)	0,279 (0,25)	0,283 (0,24)
		300	0,303 (0,16)	0,292 (0,20)	0,277 (0,19)	0,296 (0,19)	0,299 (0,19)	0,294 (0,19)
		400	0,296 (0,14)	0,300 (0,17)	0,293 (0,16)	0,302 (0,16)	0,301 (0,16)	0,302 (0,15)
		500	0,296 (0,12)	0,303 (0,14)	0,298 (0,14)	0,301 (0,14)	0,302 (0,14)	0,302 (0,13)
	2D2	200	0,324 (0,19)	0,279 (0,25)	0,270 (0,24)	0,286 (0,25)	0,278 (0,26)	0,274 (0,25)
		300	0,302 (0,17)	0,290 (0,20)	0,280 (0,20)	0,295 (0,21)	0,291 (0,20)	0,289 (0,20)
		400	0,302 (0,15)	0,297 (0,16)	0,295 (0,16)	0,299 (0,17)	0,294 (0,16)	0,302 (0,16)
		500	0,297 (0,12)	0,306 (0,14)	0,303 (0,13)	0,302 (0,14)	0,299 (0,13)	0,304 (0,14)
	2D3	200	0,317 (0,20)	0,246 (0,30)	0,252 (0,29)	0,255 (0,30)	0,254 (0,30)	0,260 (0,29)
		300	0,309 (0,17)	0,283 (0,23)	0,282 (0,22)	0,292 (0,23)	0,277 (0,24)	0,287 (0,24)
		400	0,306 (0,16)	0,288 (0,19)	0,284 (0,20)	0,288 (0,20)	0,280 (0,20)	0,294 (0,20)
		500	0,304 (0,14)	0,292 (0,17)	0,295 (0,16)	0,296 (0,18)	0,290 (0,18)	0,301 (0,17)